

UNIVERSIDAD DEL NORTE

Departamento de Ingeniería Mecánica



DISEÑO DE UNA ESTRATEGIA DE DETECCIÓN, IDENTIFICACIÓN Y
DIAGNÓSTICO DE FALLAS EN VÁLVULAS DE CONTROL QUE
INCORPORA EL DESEMPEÑO DEL LAZO DE CONTROL COMO CRITERIO
DE DECISIÓN

TESIS

Para la obtención del título de:
Magíster en Ingeniería Mecánica

KEVIN ANDRES MELENDEZ VALENCIA

Barranquilla, Colombia

Enero 2015

UNIVERSIDAD DEL NORTE

Departamento de Ingeniería Mecánica



DISEÑO DE UNA ESTRATEGIA DE DETECCIÓN, IDENTIFICACIÓN Y
DIAGNÓSTICO DE FALLAS EN VÁLVULAS DE CONTROL QUE
INCORPORA EL DESEMPEÑO DEL LAZO DE CONTROL COMO CRITERIO
DE DECISIÓN

Para la obtención del título de:
Magíster en Ingeniería Mecánica

Kevin Andrés Meléndez Valencia

Trabajo dirigido por:
Marco E. Sanjuán, PhD.

Barranquilla, Colombia

Enero 2015

TABLA DE CONTENIDO

1. INTRODUCCION.....	1
1.1. Marco Teórico.....	1
1.2. Relevancia del tema de investigación.....	3
1.3. Objetivos.....	6
1.3.1. Objetivo general.....	6
1.3.2. Objetivos específicos.....	6
1.4. Estructura del documento.....	7
2. ESTADO DEL ARTE	8
2.1. Detección de fallas: Métodos convencionales.....	8
2.1.1. Enfoque basado en modelos.....	10
2.1.2. Enfoque basado en datos.....	11
2.1.3. Enfoque basado en conocimiento.....	17
2.2. Detección de fallas: Métodos adaptativos.....	18
2.3. Detección de fallas: Combinación de técnicas.....	19
2.4. Detección de oscilaciones en lazos de control.....	19
2.5. Detección de fallas en válvulas.....	25
2.5.1. Métodos para la compensación de stiction en válvulas de control.....	29
2.5.1. Knocker.....	29
2.5.2. Refuerzo constante.....	30
2.5.3. Filtro de la señal retroalimentada.....	30
2.5.4. Compensador de dos movimientos.....	30
2.5.5. Compensación vía sintonía del controlador.....	31
3. DETECCIÓN TEMPRANA DE FALLAS UTILIZANDO VARIABLES DE LAZOS DE CONTROL.....	32
3.1. Análisis de componentes principales.....	32
3.2. Incorporación de las variables del lazo de control al análisis de componentes principales.....	37
3.2.1. Ecuaciones de sintonía para el estadístico EWMA.....	42
3.2.2. Variables escogidas para el monitoreo del proceso.....	47
3.2.3. Modelo de una válvula de control con fricción estática basado en lógica difusa.....	50
3.3. Conjunto de ecuaciones para la identificación de fallas en el espacio residual.....	57
4. METODO DE DIAGNOSTICO DE OSCILACIONES A TRAVES DE LA TENDENCIA DEL PROCESO.....	62
4.1. Identificación de tendencias de proceso.....	62
4.2. Diagnóstico de oscilaciones para procesos con estados conocidos.....	64
4.3. Diagnóstico de oscilaciones para procesos con estados no conocidos.....	71
5. VALIDACION Y ANALISIS EN UN CASO DE ESTUDIO.....	78
6. CONCLUSIONES.....	92
REFERENCIAS.....	94

LISTADO DE FIGURAS

Figura 1.1. Límites de control y comportamiento en el tiempo de la variable controlada y manipulada ante una perturbación.....	4
Figura 1.2. Límites de control y comportamiento en el tiempo de la variable controlada del lazo de control de múltiples estados de operación.....	5
Figura 2.1. Diagrama de flujo del monitoreo de procesos (adaptada de 15)...	9
Figura 2.2. Clasificación de las metodologías de detección de fallas.....	10
Figura 2.3. Carta de control de Shewhart (carta P).....	12
Figura 2.4. Carta de control CUSUM.....	13
Figura 2.5. Carta de control EWMA.....	14
Figura 2.6. <i>Grafica de monitoreo para PCA</i>	16
Figura 2.7. Calculo de la tasa de decaimiento.....	22
Figura 2.8. Diagrama de flujo para la corrección de oscilaciones en lazos de control.....	24
Figura 2.9. Relación entre la salida del controlador y la posición de la válvula de control bajo la existencia de adhesión.....	26
Figura 2.10. Error del controlador para un lazo de control agresivo (izquierda) y para un lazo con una válvula con stiction (derecha).....	27
Figura 2.11. Diagrama de bloques para un lazo de control feedback con un knocker.....	29
Figura 2.12. Diagrama de bloques para un lazo de control feedback con compensación vía filtro de la señal de salida.....	30
Figura 3.1. Ilustración grafica de la covarianza de variables correlacionadas.....	38
Figura 3.2. Distintos estados de operación del lazo de control.....	39
Figura 3.3. (a) Espacio de trabajo de un lazo de control con 4 perturbaciones. (b) Región considerada condición normal de operación.....	40
Figura 3.4. (a) Estadístico T^2 para datos en estado estable. (b) Estadístico T^2 para datos perturbados	41
Figura 3.5. Gráfico de los residuales para cada factor.....	45
Figura 3.6. (a) Estadístico T^2 para datos perturbados. (b) Estadístico κ con $\lambda = 0.05$ y $L = 4.7$ (c) Estadístico Q para datos perturbados. (d) Estadístico ϕ con $\lambda = 0.05$ y $L = 4.7$	46

Figura 3.7. (a) Estadístico κ con $\lambda = 0.05$ y $L = 4.7$ (b) Estadístico κ con $\lambda = 0.2$ y $L = 4.7$ (c) Estadístico ϕ con $\lambda = 0.05$ y $L = 4.7$ (d) Estadístico ϕ con $\lambda = 0.2$ y $L = 4.7$	47
Figura 3.8. Arquitectura del sistema de inferencia difusa.....	51
Figura 3.9. Valores lingüísticos y función de pertenencia para el indicador de magnitud.....	52
Figura 3.10. Valores lingüísticos y función de pertenencia para el indicador de sentido.....	52
Figura 3.11. Valores lingüísticos y función de pertenencia para el indicador de estado anterior (input).....	53
Figura 3.12. Valores lingüísticos y función de pertenencia para el factor β	53
Figura 3.13. Valores lingüísticos y función de pertenencia para el indicador de estado actual (output).....	54
Figura 3.14. Desempeño del modelo difuso para una válvula de control falla cerrada con inercia despreciable ($S = 5$ y $J = 0$).....	56
Figura 3.15. Desempeño del modelo difuso para una válvula de control falla cerrada con inercia despreciable ($S = 5$ y $J = 3$).....	56
Figura 3.16. Desempeño del modelo difuso para una válvula de control falla cerrada con inercia despreciable ($S = 5$ y $J = -3$).....	57
Figura 3.17. Comportamiento de los estadísticos ante la presencia de stiction. (a) Estadístico T^2 para una válvula proporcional. (b) Estadístico Q para una válvula proporcional. (c) Estadístico T^2 para una válvula isoporcentual. (d) Estadístico Q para una válvula isoporcentual. (e) Estadístico T^2 para una válvula proporcional (stiction altamente desarrollado). (f) (Estadístico Q para una válvula proporcional (stiction altamente desarrollado).....	58
Figura 3.18. Comportamiento del estadístico Q ante la presencia de stiction.....	61
Figura 3.19. Gráfico de las contribuciones de cada variable al comportamiento atípico del estadístico.....	61
Figura 4.1. Tendencia y primitivas de un lazo de control oscilatorio.....	64
Figura 4.2. Comparación de la secuencia de primitivas de dos curvas similares con distintos niveles de ruido.....	65
Figura 4.3. Arquitectura del sistema cálculo de similitud difuso.....	65
Figura 4.4. Valores lingüísticos y función de pertenencia para $P_r D_1$	66
Figura 4.5. Valores lingüísticos y función de pertenencia para $P_r D_2$	67

Figura 4.6. Valores lingüísticos y función de pertenencia para P_1D_2	67
Figura 4.7. Valores lingüísticos y función de pertenencia para P_2D_2	68
Figura 4.8. Valores lingüísticos y función de pertenencia para el indicador similitud.....	68
Figura 4.9. Identificación de la tendencia con mayor índice de similitud global dentro de un mismo grupo de referencia.....	71
Figura 4.10. Comparación de dos tendencias de un lazo de control oscilatorio debido a una mala sintonía.....	72
Figura 4.11. Respuesta subamortiguada de un sistema de segundo orden (Tomada de [91]).....	73
Figura 4.12. Comparación del ajuste de la reconstrucción para (a) controlador agresivo (b) válvula con fricción estática.....	76
Figura 5.1. Reactor endotérmico de flujo continuo.....	78
Figura 5.2. Dinámica de las perturbaciones en el set de entrenamiento.....	83
Figura 5.3. Estadístico de Hotelling para el estado estable del proceso.....	84
Figura 5.4. Estadístico κ para el estado estable del proceso.....	85
Figura 5.5. Comparación de los estadísticos Q y ϕ para el estado estable del proceso.....	85
Figura 5.6. Comportamiento de los estadísticos convencionales vs comportamiento de los estadísticos EWMA ante una falla súbita. (a) y (b) estadísticos convencionales, (c) y (d) estadísticos transformados.....	86
Figura 5.7. Comportamiento de los estadísticos convencionales vs comportamiento de los estadísticos EWMA ante una falla insipiente. (a) y (b) estadísticos convencionales, (c) y (d) estadísticos transformados.....	87
Figura 5.8. Gráfico de las contribuciones de cada variable al comportamiento atípico del estadístico, falla insipiente; crecimiento anormal en la concentración de entrada.....	88
Figura 5.9. Estadísticos convencionales ante la presencia de fricción estática en la válvula (a) Estadístico T^2 (b) Estadístico Q	89
Figura 5.10. Gráfico de las contribuciones de cada variable al comportamiento atípico del estadístico, fricción estática en la válvula.....	89
Figura 5.11. Comportamiento de la variable controlada. (a) Controlador correctamente sintonizado, sin stiction. (b) Controlador correctamente sintonizado, con stiction. (c) Controlador incorrectamente sintonizado, sin stiction. (d) controlador incorrectamente sintonizado, con stiction.....	90
Figura 6.1. Incorporación de los métodos desarrollados con un esquema de control adaptativo.....	93

LISTADO DE TABLAS

Tabla 3.1. Factores experimentales y niveles de operación.....	43
Tabla 3.2. Valores óptimos de λ y L para cada corrida experimental.....	44
Tabla 3.3. Tabla ANOVA para el modelo de regresión.....	44
Tabla 3.4. Resumen del análisis de los coeficientes de regresión.....	45
Tabla 3.5. Variables del lazo de control seleccionadas para el monitoreo del proceso.....	48
Tabla 3.6. Reglas difusas usadas en el sistema de inferencia difusa.....	54
Tabla 4.1. Lenguaje fundamental del análisis de tendencias: Primitivas.....	63
Tabla 4.2. Reglas para el apareamiento difuso de las primitivas.....	68
Tabla 4.3. Matriz de similitud de primitivas.....	69
Tabla 5.1. Parámetros de operación del reactor endotérmico.....	81
Tabla 5.2. Listado de instrumentos ETR.....	82
Tabla 5.3. Variables del lazo de control seleccionadas para el monitoreo del proceso.....	82
Tabla 5.4. Propiedades de los estadísticos de prueba.....	84

1. INTRODUCCIÓN

En este capítulo se realiza la introducción a la temática de la investigación. Inicialmente se realiza una contextualización a la problemática tratada, en donde se aborda el contexto del monitoreo de procesos. En segundo lugar, se presenta un análisis de la relevancia de la investigación, donde se exponen algunas de las falencias de la ejecución actual del monitoreo de procesos y se exhibe el vacío que se pretende llenar con el desarrollo de la investigación. Finalmente se presentan los objetivos que se persiguen y la estructura general de la presente investigación.

1.1. Marco teórico

Las restricciones de calidad, la constante necesidad de optimización y el deseo de independizar los procesos de la acción humana, han provocado un incremento progresivo en la automatización de los procesos industriales desde los años 60 hasta la actualidad [1]. Esto ha permitido que las industrias cuenten con procesos complejos y altamente instrumentados, lo cual resulta en una gran cantidad de datos de operación disponibles. Esta cantidad de datos históricos, al igual que los nuevos datos tomados cada periodo de muestreo, pueden ser utilizados para detectar comportamientos atípicos o desviaciones no deseadas de las variables de proceso, o del comportamiento global del proceso.

La automatización de procesos puede dividirse en tres etapas: Control automático, Supervisión y acciones globales como la coordinación, optimización y la administración. La principal diferencia entre estas etapas es la velocidad con la que se ejecuta cada actividad. La primera etapa (control) o nivel bajo, el cual está en línea directa con el proceso, puede ejecutarse cada fracción de segundo, limitada principalmente por la capacidad de las tarjetas de adquisición con la que se trabaje. La segunda y la tercera capas se ejecutan en el orden de los minutos (o fracciones de estos) y las horas respectivamente. El objetivo de todas estas etapas, indiferentemente de su tiempo de ejecución, es optimizar el desempeño y la calidad del proceso. Para cumplir este objetivo, en el nivel operacional se encuentran lo que se conoce como controladores de proceso estándar, mercado dominado por los controladores tipo PID, los cuales se encargan de mantener la operación del proceso en condiciones satisfactorias

mediante la compensación de los efectos de las perturbaciones o cambios de la condición de operación. Sin embargo, existen cambios que deterioran el desempeño del lazo tales como: cambios en los parámetros de proceso, envejecimiento de los actuadores y saturaciones en los sensores, mayormente [15]. Variaciones como las anteriores, que alteran el normal desempeño del proceso, y por ende el lazo de control, se denominan fallas.

En la segunda etapa, supervisión, se integran funciones como la detección de la falla (manifestar su existencia), identificación de la falla (determinar variables involucradas) y el diagnóstico de la falla (determinar tipo, localizar y evaluar severidad de la falla), para de esa forma realizar el seguimiento, registro histórico y generación de alarmas de áreas operativas y de mantenimiento de la organización. Para realizar esta actividad es necesario el uso de indicadores provenientes o asociados al sistema bajo estudio que describan su comportamiento típico; de esta forma se puede comparar con el estado actual con el típico y determinar la existencia de una condición atípica de operación o falla.

De acuerdo a la manera como se obtienen los indicadores, el proceso de monitoreo se puede dividir en tres enfoques [15]. El primer enfoque obtiene las medidas a partir de modelos analíticos y esta caracterizado por brindar una fácil interpretación de los datos y de sus desviaciones. Este enfoque utiliza relaciones matemáticas entre las variables de proceso en forma de ecuaciones para su definición y es aplicado principalmente cuando se tiene información abundante y sistemas con pocas entradas, salidas y estados [88]. Dado que en la mayoría de los procesos industriales dichos modelos resultan costosos de desarrollar, se ha extendido el uso las técnicas de monitoreo estadístico de procesos (segundo enfoque: basado en datos) en lugar de técnicas basadas en modelos. Finalmente, si se cuenta con pocos sensores o modelos imprecisos del proceso el enfoque a considerar es el basado en conocimiento. Este último es aplicado igualmente a sistemas con pocas entradas, salidas y estados, pero pretende utilizar modelos cualitativos para describir el proceso [88]. Dado que los procesos actuales son de gran escala, altamente no lineales y con variables correlacionadas entres sí, el enfoque basado en datos resulta ser más rentable a la hora de una implementación.

Las técnicas de detección de fallas basadas en datos a su vez se dividen en dos tipos: Univariante y multivariante. Las cartas de control de Shewhart, y las cartas EWMA y CUSUM son ejemplos de técnicas

univariadas de monitoreo estadístico de procesos. Estas cartas utilizan el método tradicional de límite de detección, el cual compara las observaciones de cada variable, o su estadístico transformado, con su respectivo límite definido y cuando éste es superado emite una señal de alarma. Este método, aunque sencillo, no es adecuado para los procesos industriales complejos, puesto que no considera la correlación entre las variables que está monitoreando. Los métodos multivariados consideran las correlaciones y las covarianzas entre las variables en su ley de monitoreo, lo cual las hace comúnmente más robustas que las técnicas univariadas.

Las técnicas de detección de fallas multivariadas más populares son el análisis de componentes principales (PCA), mínimos cuadrados parciales (PLS), el análisis de componentes independientes (ICA) y el análisis de variables canónicas (CVA). Para aplicar cada una de las técnicas se debe tener en cuenta principalmente la calidad y cantidad de información disponible así como las características del proceso, la relación existente entre las variables, cumplimiento de supuestos estadísticos en las etapas de construcción de los modelos y las particularidades de la técnica dado que atacan el mismo objetivo pero con distintos enfoques, entre otras [88].

Al igual que en los métodos univariados, las técnicas descritas se basan en el cálculo de un estadístico a partir de la información del proceso; este se compara con un umbral preestablecido y así se determina la ocurrencia o no de la falla. La efectividad de esta comparación está estrictamente ligada a la cantidad y la calidad de los datos tomados.

1.2. Relevancia del tema de investigación

Aunque en los procesos industriales existen múltiples fuentes de fallas, como elementos mecánicos o de bombeo con desperfectos, pérdidas de desempeño en los sistemas de enfriamiento, taponamiento o bloqueo en los medios de transporte o comunicación, el lazo de control también puede ser una fuente de falla dentro del proceso, típicamente originado por dos alternativas: una sintonización no adecuada del controlador PID (en concordancia con la dinámica actual del proceso) o un funcionamiento no adecuado de la válvula de control. Las técnicas tradicionales de detección están orientadas a considerar un espectro amplio de variables sin distinguir atributos típicos o específicos de los procesos de origen. Además, los operadores de proceso utilizan el mal desempeño del lazo de control

como un potencial indicador de problemas en la válvula, lo cual no está directamente correlacionado. Esto hace que se limite la posibilidad de utilizar técnicas de auto-sintonía o sintonía adaptativa en el controlador, porque estarían ocultando una posible falla en la válvula. Esta investigación aborda el desarrollo de técnicas de detección, identificación y diagnóstico de fallas, específicamente orientadas al lazo de control y con la capacidad de separar en la etapa de diagnóstico, las fallas debido a la sintonía del controlador y aquellas debidas a fallas en las válvulas. De esta forma no solo se desarrolla una técnica automática de detección de fallas, específica para lazos de control, pero generalizable en el sentido de que puede utilizarse para cualquier lazo de control, sino también viabiliza la utilización de esquemas de sintonía adaptativa, pues ya se sabría el momento adecuado de acción de estas técnicas.

La técnica de detección de fallas más comúnmente utilizada para procesos de múltiples variables es el análisis de componentes principales (PCA). En esta técnica se detecta una falla si una o más variables monitoreadas se desvían de su condición normal de operación. Una falla puede ocurrir en una variable no medida, sin embargo, el conocimiento del proceso se limita a las señales de los instrumentos. Estas señales suelen estar ligadas a lazos de control encargados de compensar las perturbaciones que entren al mismo, por ese motivo, si un lazo de control mitiga la desviación de las variables medidas de su valor deseado, se está perdiendo la capacidad de detectar fallas en las variables no monitoreadas.

Si se utilizan variables del lazo control, con las cuales se pueda cuantificar el desempeño del lazo (como por el ejemplo el error y el error de modelaje), para detectar comportamiento atípico del proceso, se puede compensar el efecto del controlador sobre la capacidad de detección de fallas de un método, al tiempo que se introduce la capacidad de detectar fallas que no se podrían detectar utilizando únicamente la información provista por los sensores de las variables del proceso. En la figura 1.1 se presenta el caso más simple de lo expuesto anteriormente.




Figura 1.1. Límites de control y comportamiento en el tiempo de la variable controlada y manipulada ante una perturbación

En la figura 1.1 se muestra cómo responde un lazo de control ante la entrada de una perturbación gran magnitud, la cual no se encuentra presente en condición normal de operación; esto sugiere una condición atípica del proceso. Como se observa, el controlador compensa el efecto de la perturbación antes de que la variable controlada salga fuera de sus límites de control, por lo cual la falla sería pasada por alto si solo se utiliza la información del sensor. Sin embargo, se nota que la señal del controlador cae drásticamente; este comportamiento puede aprovecharse para detectar fallas que serían cubiertas por el lazo de control.

Incluso incluyendo las variables del lazo de control en el set de datos, existen ciertos tipos de fallas que no pueden detectarse tempranamente utilizando los métodos convencionales de detección. Uno de ellos es el pobre desempeño de un lazo de control. En la figura 1.2 se muestra la repuesta de la variable controlada de un lazo de control, del cual se sabe que posee dos condiciones de operación conocidas y planeadas.




Figura 1.2. Límites de control y comportamiento en el tiempo de la variable controlada del lazo de control de múltiples estados de operación

Al tener dos condiciones de operación, el rango de operación de la variable controlada es amplio, pues se le permite variación. No obstante, pese a que la variable permanece dentro de sus límites de control, por lo cual los métodos convencionales no verían una falla, el comportamiento oscilatorio que posee la variable controlada no es deseable y debe considerarse como una falla en el desempeño del lazo de control. Si bien es posible apreciar las oscilaciones por inspección, esto resulta una tarea tediosa para el operador, puesto que en una planta industrial se cuentan con cientos de lazos de control; se desea incluir estos deterioros en el desempeño de los lazos en la estrategia a diseñar, evitando así la propagación de la falla al resto del proceso.

Para eliminar las oscilaciones excesivas una vez son detectadas, es necesario cambiar la sintonía del controlador por una menos agresiva. A menos que la causa de las oscilaciones se otro lazo oscilando, cambiar la sintonía del controlador reducirá la presencia de las oscilaciones. Si bien desde el punto de vista del desempeño del lazo de control, esta acción es la adecuada, analizándolo desde el punto de vista de la detección de fallas, esto podría traer ciertos aspectos a considerar. Si no es una perturbación externa la causa de las oscilaciones, esta puede deberse principalmente a dos razones: Cambio de la condición de operación (nolinealidades o envejecimiento del proceso) y problemas en el actuador el lazo. Si se trata de un cambio en la condición de operación, resintonizar es una buena

opción para compensar la falla, sin embargo, si las oscilaciones se deben a un falla en la válvula de control, cambiar la sintonía resolverá el problema de las oscilaciones, pero ocultaría la presencia de la falla en la válvula hasta que tenga determinada severidad, lo cual impediría el mantenimiento oportuno de la válvula. Durante el desarrollo de esta investigación se pretende desarrollar una técnica de diagnóstico de las oscilaciones para determinar si su fuente es debido a una mala sintonía del controlador o a problemas con la válvula de control.

1.3. Objetivos

1.3.1. Objetivo general

Diseñar una estrategia de detección temprana, identificación y diagnóstico de fallas que utilice el desempeño de los lazos de control como criterio de decisión, con la capacidad de discernir, en la etapa de diagnóstico, si un mal desempeño se debe a un controlador pobremente sintonizado o a alteraciones en la válvula de control.

1.3.2. Objetivos específicos

- ❖ Diseñar un conjunto de variables exclusivas de lazos de control que permitan un entrenamiento oportuno del método de detección de fallas.
- ❖ Identificar técnicas estadísticas que permitan al sistema operar aún bajo condiciones de entrada de perturbaciones.
- ❖ Diseñar un modelo que incorpore la presencia de fricción estática en las válvulas.
- ❖ Evaluar la presencia de fricción estática en las válvulas de control utilizando la tendencia de las variables del lazo de control.

1.4. Estructura del documento

Para abordar la problemática planteada, en el capítulo 2 se presenta una revisión del estado del arte. En ella se trata de manera más amplia los distintos métodos de detección de fallas y detección de oscilaciones en lazos de control. En el capítulo 3 se presenta la incorporación de las variables del lazo de control como las variables del set de entrenamiento y monitoreo del análisis de componentes principales. Por otro lado, también se presenta el desarrollo de un modelo basado en lógica difusa del comportamiento de una válvula de control que presenta fricción estática, el cual será usado para obtener unas de las variables requeridas para poder detectar la fricción estática utilizando PCA. Por último, en este capítulo se presenta el desarrollo de una nueva metodología de identificación de fallas en el espacio residual. Este último ítem del capítulo busca resolver el inconveniente que surge cuando las variables relacionadas con la válvula no son significativas en los componentes principales. El capítulo 4 por su parte, muestra el desarrollo de una técnica de diagnóstico de oscilaciones mediante comparación de tendencias. En primer lugar se presenta una metodología para procesos lineales y/o de estados conocidos, y seguido se introduce una metodología recomendada para procesos no lineales, o de los cuales no se tiene suficiente información. En el capítulo 5 se muestra la validación y análisis de desempeño de los métodos desarrollados en un caso de estudio propuesto. Finalmente se presentan las conclusiones del trabajo y futuras investigaciones en el capítulo 6.

2. ESTADO DEL ARTE

En la siguiente sección se realiza una revisión del estado del arte. Dado que la idea general tras este documento es la detección de fallas a partir del desempeño del lazo de control, discriminando si el comportamiento atípico del lazo se debe a fallas en la válvula de control o a un controlador pobremente sintonizado, la revisión literaria se dividió en 5 partes y de esta forma abarcar organizadamente toda la temática. En la primera sección se revisan las técnicas de detección de fallas convencionales y se presentan los distintos enfoques encontrados en la literatura. En segundo lugar, se revisan las técnicas adaptativas de detección de fallas, es decir aquellas técnicas que tienen en cuenta las variaciones del proceso en el tiempo. En tercer lugar se presentan algunas combinaciones de distintas técnicas de detección de fallas. La cuarta sección presenta algunas metodologías para la detección y diagnóstico de oscilaciones en lazos de control, lo cual es el mayor indicio de problemas dentro de un lazo de control. Finalmente se presentan algunas técnicas encontradas en la literatura para identificar y/o compensar fallas en las válvulas de control.

2.1. Detección de fallas: Métodos convencionales

La detección de fallas hace parte de una etapa más grande llamado monitoreo de procesos. En la figura 2.1 [15], se muestran las etapas asociadas al monitoreo de procesos. Si el proceso está en condición normal de operación se encuentra activo el modo de *detección de fallas*, lo cual consiste en determinar si una falla ha ocurrido o no. En caso de que se detecte una, el siguiente paso es *identificar la falla*, es decir, determinar qué variables son significativas para el diagnóstico de la falla. Seguidamente se realiza el *diagnóstico de la falla*, en el cual se determina la causa, la ubicación, magnitud y tiempo de ocurrencia de la falla, para finalmente entrar a la etapa de *recuperación del proceso*; es decir, tomar acciones correctivas para llevar de nuevo al proceso a una condición de operación normal.

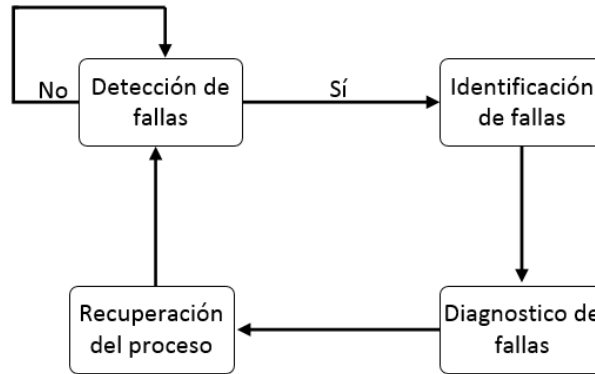


Figura 2.1. Diagrama de flujo del monitoreo de procesos (adaptada de [15])

De acuerdo al tipo de modelo o enfoque utilizado para abordar la problemática, los métodos de detección de fallas pueden dividirse en tres grupos; si no existe un modelo explícito, sino que se utilizan datos reales del proceso para describir el comportamiento del mismo, se dice que se está utilizando un enfoque *basado en datos*. Si por el contrario existe un modelo explícito (matemático), construido basado en principios físicos, que describa la dinámica del proceso se dice que se está usando un enfoque *analítico* (también se le conoce como *basado en modelos*). Finalmente, si se utilizan reglas procedentes de la experiencia, modelos cualitativos o sistemas expertos, se dice que se está utilizando un enfoque *basado en conocimiento*. El enfoque analítico y el basado en conocimiento tienen su mayor aplicabilidad en sistemas con un número relativamente pequeño de variables y estados [15]. En la figura 2.2 se presenta un mapa con los distintos enfoques utilizados en la detección de fallas.

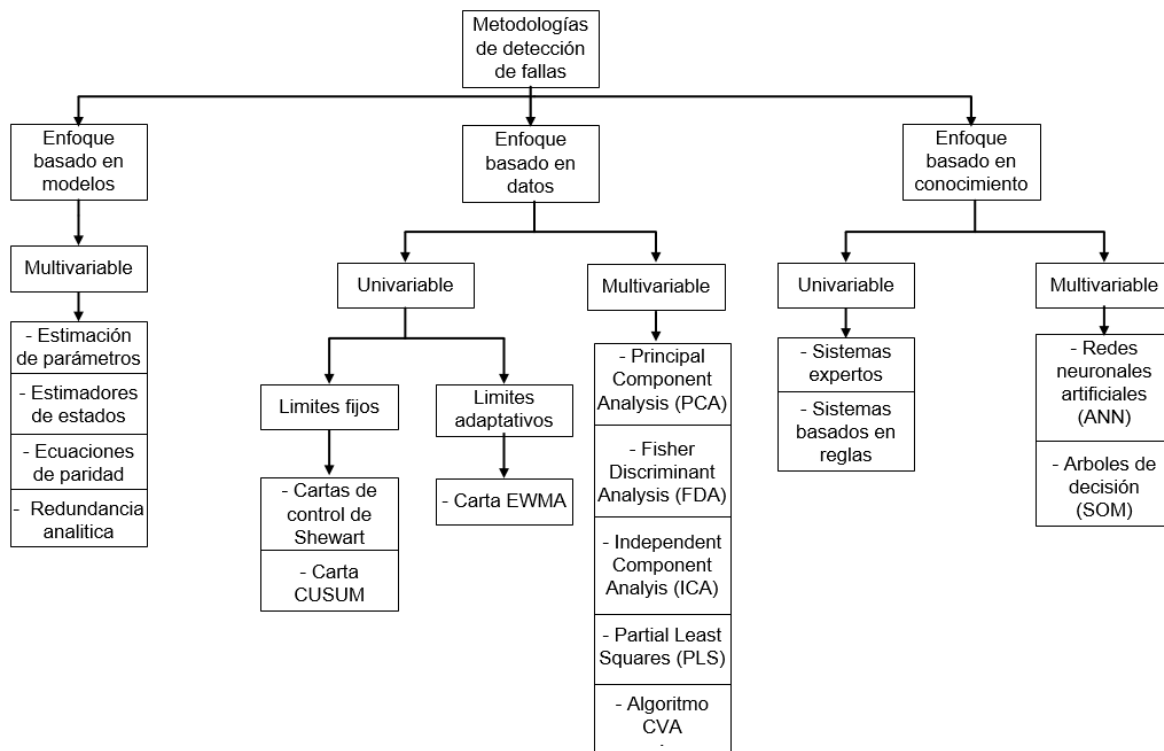


Figura 2.2. Clasificación de las metodologías de detección de fallas

Sin importar el tipo de enfoque utilizado, las técnicas de detección de fallas requieren la toma de datos del proceso, bien sea para compararlos con alguna referencia preestablecida, o para el cálculo de estadísticos que de igual manera se utilizan para ser evaluados. Por este motivo se requiere que el proceso se encuentre correctamente instrumentado. Se busca convertir la gran cantidad de datos disponibles en unas cuantas medidas significativas del estado del proceso y así asistir a los operadores a detectar e identificar fallas en los procesos. A continuación se presenta un resumen de cada uno de los métodos anteriormente mencionados.

2.1.1. Enfoque basado en modelos

El enfoque analítico fue el más utilizado hasta 1997 [17]. El método más común utilizado en este enfoque es el llamado *detección por discrepancia*, el cual consiste en comparar el valor actual medido de cada variable con un valor predicho por un modelo analítico y si se encuentra que la diferencia es significativa, se activa una alarma indicando la existencia de una falla. La principal desventaja de esta metodología, y de este enfoque en general, es la necesidad de tener un modelo analítico que describa de manera precisa el comportamiento del proceso, lo cual es difícil de obtener

si se trata de procesos multivariantes altamente complejos y no-lineales [16]. Si se cuentan con los principios físicos que describen correctamente al proceso, este enfoque puede brindar un monitoreo del procesos riguroso, siendo de gran utilidad en la detección y el diagnóstico de la falla. Sin embargo, a medida que se incrementan el número de variables y la complejidad del sistema, se hace más difícil el modelamiento matemático de dichos principios físicos. En algunas ocasiones, las fallas del proceso están asociadas a cambios en variables de estado no medibles, es dichos casos se utiliza el enfoque de *estimación de estados*. Los estados son estimados a partir de las variables de salida medibles utilizando un observador de estado [15]. Por otro lado, si las fallas en el proceso están asociadas a cambios en los parámetros del proceso, se utiliza el enfoque de *estimación de parámetros*. Los modelos analíticos permiten relacionar los parámetros del modelo con parámetros reales del proceso. Se pueden establecer umbrales para la diferencia individual entre los parámetros nominales de proceso y los parámetros estimados [18]. En los dos casos presentados anteriormente se puede aplicar la *redundancia analítica*, con lo cual se utilizan los modelos explícitos para generar y evaluar los residuales [19]. En el caso de estimación de parámetros los residuales se calculan a partir de la diferencia entre el valor medido y el valor predicho por el modelo, y en el caso de la estimación de estados, los residuales se calculan como la diferencia entre las variables nominales de estado y las variables de estado estimadas.

2.1.2. Enfoque basado en datos

El enfoque basado en datos se fundamenta en principios y modelos estadísticos. Los métodos estadísticos univariantes más ampliamente utilizados son las cartas de control de Shewhart. En la figura 2.3 se muestra la carta de control para la fracción disconforme como ejemplo de una carta de control típica. La carta de control contiene una línea central que representa el valor promedio de la característica de la calidad que corresponde al estado bajo control. También se muestran dos líneas que corresponden al límite de control superior (UCL) y el límite de control inferior (LCL). Estos límites se eligen de tal forma que si el proceso está bajo control, la mayoría de los puntos muestrales se localizan entre ellos. Si los puntos graficados se encuentran dentro de los límites se dice que el proceso se encuentra bajo control, sin embargo si uno o más puntos se encuentran fuera de los límites de control o los datos presentan alguna

tendencia, se dice que una falla ha ocurrido. Normalmente los límites de control se escogen a 3 desviaciones estándares de la media [20].




Figura 2.3. Carta de control de Shewhart (carta P)

Las cartas de control de Shewhart constituyen una técnica de control estadístico de procesos que se basa en la suposición de que un proceso sujeto a una variabilidad natural se mantendrá en un estado de control estadístico bajo el cual ciertas variables de proceso se mantienen cerca de sus valores deseados [21]. Una de las principales desventajas de las cartas de control de Shewhart es que solo utiliza la información del proceso contenida en el último punto graficado e ignora la información ofrecida por la secuencia completa de datos. Esta característica hace que las cartas de control de Shewhart sean relativamente poco sensibles a los corrimientos pequeños de la media (1.5σ) [20]. Pueden utilizarse dos alternativas a las cartas de Shewhart cuando el interés son corrimientos pequeños: la carta de control de suma acumulada (CUSUM) y la carta de control del promedio móvil ponderado exponencialmente (EWMA).




Figura 2.4. Carta de control CUSUM

En la figura 2.4 se muestra una carta de control CUSUM, en ella se grafican la suma acumulativa de muestras de la variable de proceso [20, 22]. Algunos autores, como [22] y [23], sugieren la ponderación de cada suma, sin embargo, el estadístico normalmente se calcula a partir de:

$$C_i = \sum_{j=1}^i (\bar{x} - \mu_0)$$

Por otro lado, en la figura 2.5 se muestra una carta de control EWMA. Esta es una carta de control utilizada para monitorear variables del proceso independientemente, utilizando un paquete de datos históricos como entrenamiento y una serie de datos como puntos a comparar [24]. La carta EWMA pondera las muestras en un orden geométricamente decreciente de tal forma que las muestras más recientes tienen un mayor peso sobre aquellas más distantes. El promedio móvil ponderado exponencialmente se define como:

$$z_i = \lambda x_i + (1 - \lambda)z_{i-1}$$

Donde $0 < \lambda \leq 1$ es una constante, y el valor inicial es el objetivo del proceso, de tal modo que $z_0 = \mu_0$. Al igual que las cartas de Shewhart, la carta EWMA tiene límite inferior y superior, los cuales son móviles, a diferencia de en las cartas de Shewhart. Los límites de control para la carta EWMA se calcula a partir de:

Límite superior:

$$UCL = \mu_0 + L\sigma \sqrt{\frac{\lambda}{2-\lambda} [1 - (1-\lambda)^{2i}]}$$

Límite inferior:

$$LCL = \mu_0 - L\sigma \sqrt{\frac{\lambda}{2-\lambda} [1 - (1-\lambda)^{2i}]}$$

Donde L es la amplitud de los límites de control. La carta EWMA es muy efectiva contra los corrimientos pequeños en la media proceso, sin embargo tiene dos parámetros de diseño que deben prestablecerse antes de poder utilizar la carta: el múltiplo de sigma usado en los límites de control (L) y el valor de λ . Crowder et al [25] y Saccucci et al [26] estudiaron estos factores de diseño y se determinaron los valores de los parámetros: $L = 3$, es decir los tres σ usualmente usados funcionan razonablemente bien, y valores de λ entre 0.05 y 0.25 funcionan bien en la práctica, siendo $\lambda = 0.2$ la elección más común [20].




Figura 2.5. Carta de control EWMA

Los métodos estadísticos univariados, como lo son las cartas de control, establecen umbrales que no pueden ser sobrepasados por la variable de interés en el instante medido. Esta metodología se denomina “*Limit Sensing*” y ha sido ampliamente utilizada debido a lo fácil que es su implementación e interpretación, sin embargo carece de sensibilidad en

procesos complejos ya que no considera ni las correlaciones espaciales entre las distintas variables del proceso, ni las correlaciones temporales [15]. Por ese motivo, en procesos complejos que presenten correlaciones entre sus variables, resulta más provechoso utilizar técnicas multivariantes que tengan en cuenta dichas correlaciones y las no linealidades del proceso.

Las técnicas de detección de fallas multivariantes son básicamente técnicas de reducción dimensional que captura la variabilidad de los datos en un espacio de pequeña dimensión, el cual es ampliamente utilizado en el monitoreo de procesos. Para algunas aplicaciones, la mayor parte de la variabilidad de los datos puede ser capturada en dos o tres dimensiones, y de esta forma la variabilidad del proceso puede observarse en una simple gráfica [27]. La figura 2.6 muestra un ejemplo de las cartas de monitoreo de procesos multivariantes. Esta visualización gráfica y la estructura extraída de los datos multidimensionales ayudan a los ingenieros a identificar las tendencias significativas en los datos del proceso [28]. *Principal Component Analysis (PCA)*, es la más popular de estas técnicas. El amplio uso de PCA se debe a tres motivos. Primeramente, PCA produce una representación de menor dimensión de los datos, lo cual describe mejor a los datos independientes del paquete de entrenamiento, que si se utilizara la dimensión total del espacio de observación, lo cual incrementa la capacidad de detectar y diagnosticar fallas. En segundo lugar, la estructura obtenida por PCA permite identificar las variables responsables de la falla y/o las variables más afectadas por la falla. Finalmente, PCA puede separar el espacio observado en dos subespacios; en el primero de ellos captura las tendencias sistemáticas del proceso, y el segundo contiene esencialmente ruido aleatorio [15]. Puesto que ciertas fallas afectan a uno de los dos subespacios [29], analizando los subespacios independientemente se puede incrementar la sensibilidad del esquema general de monitoreo de procesos. Por otro lado, en PCA un gran número de variables pueden ser transformadas en estadísticos simples (T^2 de Hotelling y Q), los cuales pueden ser mostrados cada uno en una gráfica y comparados con un umbral estadístico tal y como se hace en las cartas univariantes [30].




Figura 2.6. Grafica de monitoreo para PCA

Aunque PCA tiene ciertas propiedades que lo hacen adecuado para la detección de fallas, tiene ciertas deficiencias al momento de diagnosticar fallas puesto que no tiene en cuenta la información entre las clases de datos cuando está realizando la reducción dimensional. *Fisher Discriminant Analysis (FDA)*, es una técnica de reducción dimensional, al igual que PCA, que provee una reducción de dimensión óptima en términos de discriminar entre las distintas clases de datos [31]. FDA ha sido ampliamente estudiado en la literatura de clasificación de patrones [15]. Aunque este método es solo un poco más complejo que PCA, no es tan utilizado en procesos industriales debido a que la literatura estadística es más popular que la literatura de clasificación de patrones. Otra técnica de reducción de dimensión es *Independent Component Analysis (ICA)*, la cual difiere de PCA principalmente porque asume que los datos provienen de fuentes que siguen una distribución no gaussiana. Además considera estadísticos de orden superior para reducir dependencias, a diferencia de PCA que sólo considera independencia respecto a la media y la varianza [32], además, extrae los componentes ocultos de los datos asumiendo solamente que los factores desconocidos son mutuamente independientes [33]. La última de las técnicas de reducción de dimensión revisada es conocida como *Partial Least Squares (PLS)*, la cual busca maximizar la covarianza entre un bloque predictor (independiente) X y un bloque predicho (dependiente) Y para cada componente del espacio reducido [34]. Esta técnica modela la relación entre X y Y usando de ajustes locales por medio de mínimos cuadrados [35]. Una aplicación popular para PLS es escoger una matriz Y que contenga datos de calidad del producto, los

cuales pueden contener mediciones fuera de línea, y una matriz X que contenga el resto de las variables de proceso [27]. Estos modelos inferenciales, también conocidos como *soft sensors*, pueden ser utilizados para la predicción en línea de la calidad del producto, también incorporarse en los algoritmos de control o supervisión de procesos [36].

2.1.3. Enfoque basado en conocimiento

Este enfoque utiliza la relación entre el patrón de comportamiento de los datos y las clases de fallas sin modelar, los estados internos del proceso o su estructura explícitamente [15]. Este enfoque se basa en técnicas de inteligencia artificial, es decir, aquellas que buscan el diseño de sistemas capaces de procesar información usando el paradigma del razonamiento humano para detectar y diagnosticar fallas. Esto incluye los *sistemas expertos*, *sistemas basados en reglas*, *redes neuronales artificiales (ANN)*, *mapas auto-organizados (SOM)*, *árboles de decisión*, entre otros [37]. Un sistema experto utilizado para detectar fallas es un sistema que almacena los conocimientos y la experiencia acumulada de expertos en detección de fallas del proceso dado, por lo cual su utilidad se limita al proceso específico en el que fue implementado, además, los sistemas expertos no pueden diagnosticar fallas no incorporadas en la base de conocimientos, por lo que no pueden adaptarse a nuevos modos de operación o a nuevas condiciones de fallas del proceso [38]. Los sistemas expertos usualmente constan de dos componentes principales; una base de conocimientos y un mecanismo de inferencia. La base de conocimientos contiene la experiencia específica requerida en el área en la que se desempeñará el sistema experto, la cual se puede expresar mediante reglas si-entonces-sino-entonces, proposiciones, marcos, objetos, procedimientos y casos [39]. Por otro lado, las redes neuronales son un paradigma para el procesamiento de información, que están inspiradas en la forma en la que las redes neuronales biológicas, tales como el cerebro humano funcionan. El bloque central de dicho paradigma es la estructura única de procesamiento de información, la cual consiste en un gran número de elementos de procesamiento altamente interconectados y organizados, los cuales se llaman *neuronas*. Una red neuronal artificial (ANN) usualmente es implementada para desempeñar una tarea en particular, tal como reconocimiento de patrones, clasificación y agrupamiento de datos, así como también detección y diagnóstico de fallas a través de un proceso de aprendizaje [38].

2.2. Detección de fallas: Métodos adaptativos

Los métodos de detección de fallas anteriormente mencionados utilizan descripciones invariantes en el tiempo de los procesos que monitorean, es decir que una vez estructurados los modelos de detección de fallas en la fase de entrenamiento, estos no cambian su estructura en el tiempo, a diferencia de los procesos reales, los cuales presentan cambios en su comportamiento en el tiempo y de acuerdo al punto de operación que se analice [40]. Cuando cualquier técnica convencional de detección de fallas es aplicada con modelos de detección de fallas fijos para el monitoreo de procesos con cambios o derivas temporales normales, las falsas alarmas eventualmente ocurrirán [38]. Las metodologías adaptativas, como su nombre lo indica, se adaptan a cambios en los procesos, para esto es necesaria la inclusión de nuevos datos que describan la dinámica del proceso y que se considere las auto-correlaciones en las variables.

Los métodos adaptativos utilizan el enfoque basado en datos como fundamento, siendo PCA el más utilizado. Buscando la disminución de la tasa de falsas alarmas, se han desarrollado varios métodos adaptativos de detección de fallas basados en PCA [41]. En [23] se presenta un método basado en PCA combinado con un umbral adaptativo para detección de fallas en un proceso experimental, el cual sensible a la varianza y se caracteriza por mitigar las falsas alarmas ocasionadas por los comportamientos transitorios de los procesos mediante la actualización constante de la varianza de del estadístico T^2 para el ajuste del umbral de detección. Por otro lado, algunas técnicas basadas en PCA incorporan nuevos datos de proceso, actualizando los modelos estadísticos de la detección. Tal es el caso de los enfoques que llevan a cabo actualizaciones recursivas de los modelos estadísticos de detección de fallas [43], así como el enfoque de actualización recursiva combinada con ventana [44]. Integrando las cartas de control EWMA y CUSUM con PCA, se ha logrado tener en cuenta auto-correlaciones en las variables. El DPCA (PCA dinámico) es otro método utilizado para incorporar las auto-correlaciones en las variables en el modelo de detección de fallas [42]. En la revisión literaria, también se encuentran algoritmos recursivos de detección de fallas basados en técnicas distintas a PCA, tal como los algoritmos propuestos por [45], los cuales están basados en PLS.

Además de los cambios en el tiempo que puede presentar un proceso, pueden tener distintos modos o patrones de operación, por lo que se debe,

en estos casos, usar técnicas de reconocimiento de patrones en la fase de identificación y diagnóstico de fallas, para discernir entre distintos tipos de condiciones normales y condiciones de falla [38].

2.3. Detección de fallas: Combinación de técnicas

Cada técnica de detección de fallas tiene sus ventajas y desventajas, por lo cual incorporar varias técnicas resulta atractivo para los investigadores, y se ha convertido en un tema de reciente estudio [15]. Samantaray et al [46] proponen una combinación de un filtro de Kalman con una red neuronal artificial para llevar a cabo detección de fallas en sistemas de distribución de energía. El desarrollo propuesto en [46] es una red neuronal de perceptrón multicapa, también conocida como Feed-forward Neural Network (FNN), que consta de múltiples entradas y dos salidas, así como también una capa oculta con cinco neuronas ocultas. Garcia et al [47] combinan modelos físicos, procesamiento neuronal y pruebas de probabilidad para la detección de fallas. Zhao et al [48] por su parte, propuso una ANN híbrida integrada con un sistema experto para el diagnóstico dinámico de fallas. Combinando una FNN una estimador adaptativo de modelos (MMAE), Zhan [49] propuso un método para la detección y diagnóstico de fallas. Por otro lado, Engelnmore et al [50] propusieron un sistema de diagnóstico de fallas compuesto por sistemas expertos de diagnósticos y planificadores, para integrar distintos métodos de diagnósticos.

2.4. Detección de oscilaciones en lazos control

Una planta industrial considerada “mediana” puede tener cientos de lazos de control, los cuales se encuentran supervisados por los operadores del proceso. Para facilitar su trabajo, se utilizan alarmas cuando el proceso se encuentra fuera de límites de control preestablecidos. Los procedimientos de detección de fallas se utilizan para predecir funcionamientos defectuosos en los equipos antes de que la falla sea catastrófica [1]. Dado que los operadores tienen tiempo limitado para dedicar a cada lazo de control, incluso con las alarmas, muchos de los lazos de control presentan comportamientos no deseados [2]. Uno de los problemas más frecuentes en los lazos de control son las oscilaciones, las cuales se deben a problemas de sintonía, no linealidades del proceso, envejecimiento del proceso, problemas en los actuadores y sensores, y otros lazos de control. En Isermann et al [2] y Ender [3] afirman que alrededor del 30% de los lazos de control son oscilatorios debido a

problemas en la válvula, el elemento final de control más común, y Hagglund [4] afirma que las oscilaciones debidas a la fricción en las válvulas se compensan usualmente re-sintonizando el controlador en lugar de llevar a cabo el mantenimiento de la válvula. Las oscilaciones causan un incremento en el consumo de energía, desperdicio de material y causan que disminuya la uniformidad del producto final [5]. El 60% de los lazos de control presenta algún tipo de problemas de desempeño [3].

Dado que el controlador es incapaz de compensar por si solo las oscilaciones descritas anteriormente, es deseable detectarlas y hacer consiente al operador de la existencia de un problema. La principal problemática para la detección es que la naturaleza de las oscilaciones puede variar considerablemente. La frecuencia puede ser tanto de bajo o medio rango. Además, las oscilaciones son a menudo muy distintas de sinusoidales puras, por ejemplo, cuando la fricción en las válvulas es elevada las ondas tienden a ser triangulares [5]. Dado que la causa de las oscilaciones usualmente se debe a la superposición de los factores anteriormente descritos, se hace difícil el diagnóstico de la falla en muchas situaciones, sin embargo Hagglund [4] propone un método simple y robusto para la detección de oscilaciones en los lazos de control.

La idea tras el procedimiento de detección de oscilaciones es analizar la integral absoluta del error entre dos cruces sucesivos del error a través de cero, decir:

$$IAE = \int_{t_{k-1}}^{t_k} |e(t)| dt$$

Donde t_{k-1} y t_k son dos instantes consecutivos en los que el error cruza el cero, además se asume que el controlador tiene parte integrante, por lo cual el error promedio del controlador es cero. Si no hay acción integral, el valor medio de la señal de medición se puede obtener usando un filtro de paso bajo [4].

Durante los períodos de buen control, la magnitud del error es pequeño, y los tiempos entre los cruces sucesivos por cero son relativamente cortos (estos dependen de la constante de tiempo del proceso, por lo cual en general no se pueden considerar como tiempos pequeños, pero en comparación a cuando hay problemas de sintonía, o cuando lazos de control acoplados interfieren entre ellos, se puede afirmar que la diferencia es significativa). Esto significa que durante un buen control, el IAE

calculado de acuerdo con la ecuación anterior es pequeño, mientras que en el caso contrario, el tiempo entre los cruces sucesivos por cero son más grandes y por lo tanto el IAE. Cuando el IAE excede cierto valor denominado como IAE_{lim} , se dice que se ha inducido una perturbación debida a un lazo de control. El valor del IAE_{lim} se escoge jugando con el error tipo I y tipo II, es decir, con la probabilidad de no detectar una oscilación dado que la haya y detectar oscilaciones inexistentes estadísticamente (falsas alarmas). Se recomienda utilizar calcular el IAE_{lim} como sigue:

$$IAE_{lim} = \frac{2a}{w_u}$$

En donde w_u , es la frecuencia ultima del lazo y a es la amplitud máxima tolerada. Para la deducción de esta fórmula se asumió que el comportamiento del error era netamente sinusoidal. Si el controlador fue sintonizado utilizando métodos de sintonía en línea, el valor w_u es conocido [6], pero normalmente este valor no se conoce. Si el controlador está correctamente sintonizado, una buena estimación de la escala de tiempo del proceso es el tiempo integrativo τ_I . Con un controlador PI (D) correctamente sintonizado el valor de τ_I tiene un valor aproximado al periodo ultimo de oscilación T_u [4]. Si w_u es desconocido puede ser reemplazado por:

$$w_u \cong \frac{2\pi}{\tau_I}$$

El método de detección se puede resumir de la siguiente manera: Si la cantidad de veces que se detectan $IAE's$ mayores que IAE_{lim} es mayor a un n_{lim} en un periodo de supervisión T_{sup} , se concluye que hay oscilaciones en el lazo de control.

El procedimiento de detección de oscilación se basa en el error del lazo, excepto cuando el controlador no tiene parte integrativa. Para estos controladores, se sugiere analizar la diferencia entre la señal de medición y su valor medio obtenido de un filtro de paso bajo. Podría ser ventajoso utilizar el segundo enfoque también para los controladores con parte integrativa, ya que ofrece la posibilidad de detectar oscilaciones que no están centradas alrededor del setpoint [4]. Esta metodología de detectar oscilaciones mediante el cálculo del IAE entre dos puntos consecutivos en el que el error cruza el cero también es estudiada por Forsman et al [7] años después.

Miao et al [8] utiliza una metodología basada en métodos estadísticos en donde básicamente se propone que si algún momento la tasa de decaimiento de la función de auto correlación supera un límite establecido, se afirma que el sistema está oscilando. La dependencia estadística de una serie de datos en el tiempo puede ser caracterizada por el coeficiente de auto correlación δ_k , definido como:

$$\delta_k = \frac{\sum_{t=1}^{N-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^N (Z_t - \bar{Z})^2}$$

Donde Z_t es el valor medido en el tiempo t ($t=0, 1, 2, \dots$), N es el número de datos, \bar{Z} es la media de la muestra y k denota la posición del lag. La figura 2.10 ilustra la definición de la tasa de decaimiento R , la cual es un estimador de que tan oscilatorio una respuesta en el tiempo es. La tasa de decaimiento está definida como $R = a/b$, donde b es la distancia entre el primer mínimo y la línea recta que junta la imagen del lag cero y el primer máximo, y a es la distancia entre el primer máximo y la línea recta que junta los dos primeros mínimos. Si la respuesta del lazo de control es estable $R < 1$ [8].




Figura 2.7. Calculo de la tasa de decaimiento

Miao [8] utiliza como valor límite $R = 0.5$, sin embargo es ventajoso tener este valor en función de la cantidad de datos. Un método similar al propuesto en [8] es utilizado por Thornhill et al [9] con la adición de un filtro de paso bajo para incrementar la robustez ante el ruido. Srinivasan et al [10] presentan un método para caracterizar oscilaciones en las mediciones de lazos de control en procesos químicos. El método propuesto utiliza una descomposición empírica en modos (DEM) para descubrir todos

los cruces por cero en los datos. El objetivo del método DEM es descomponer la señal original en una suma de componentes oscilatorios denominados “Funciones de Modo Intrínseca (FMI)”. Thornhill et al [11] propusieron un conjunto de procedimientos para detectar y diagnosticar los lazos oscilantes a partir de datos fuera de línea. Así mismo Tangirala et al [13] también utiliza métodos visuales y análisis de frecuencia para detectar oscilaciones en plantas industriales; presentan una gráfica denominada mapa de correlación de potencia espectral (PSCMAP). En [14] se presentó un procedimiento de detección de oscilaciones utilizando la transformada de Wavelet. Análisis Wavelet es actualmente una herramienta popular para el análisis de los datos no estacionarios, basada en un análisis espectral de Fourier con ventana ajustable, dando una caracterización tiempo-frecuencia de la señal y es útil en el análisis de datos con cambios de frecuencia graduales.

Una forma sencilla, aunque no robusta de diagnosticar y corregir las oscilaciones de un lazo de control, se presenta en la figura 2.8 [4]. Básicamente divide las causas de las oscilaciones en dos grupos: oscilaciones debidas a la lazo de control y oscilaciones externas a la lazo de control. Cuando la causa de las oscilaciones se encuentra en el lazo de control, se deben a la válvula de control o a la sintonía del controlador, de lo contrario se debe a una perturbación grande al lazo. La metodología para eliminar las oscilaciones en ambos casos se presentan en la misma figura.

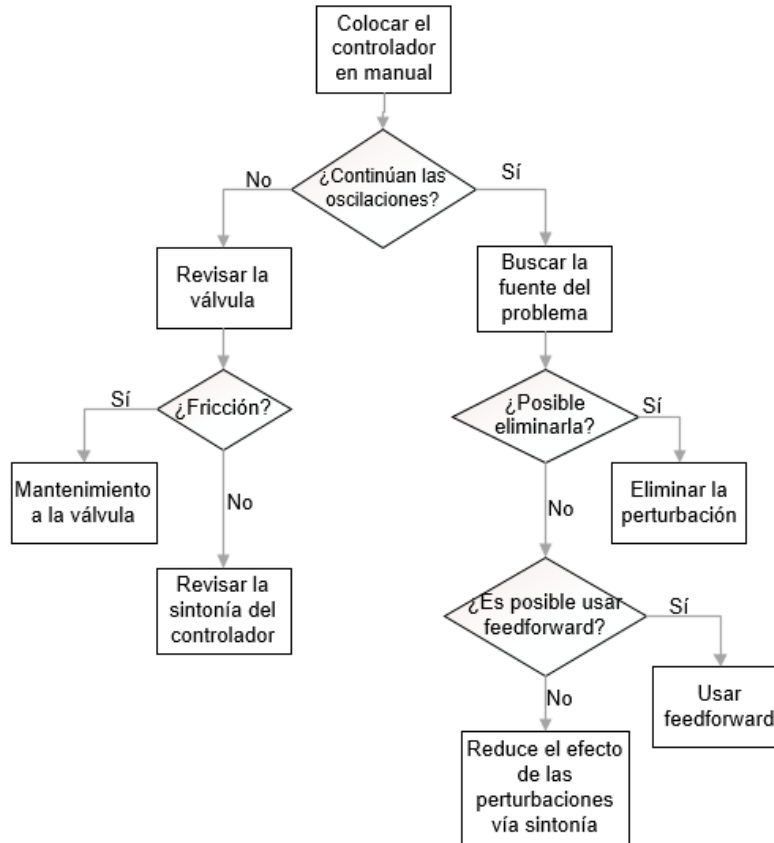


Figura 2.8. Diagrama de flujo para la corrección de oscilaciones en lazos de control.

Aunque la metodología propuesta por Hagglund [4] es sencilla, muchas veces no es viable colocar el controlador en manual para realizar la prueba, especialmente si se tienen varios lazos de control. Por otro lado, Desborough et al [12] combinaron técnicas de evaluación del rendimiento del controlador en conjunto con graficas del proceso y análisis espectrales del error del controlador para realizar diagnóstico de las oscilaciones y han probado su metodología en distintos lazos industriales. La temática de detección de oscilaciones en lazos de control está ampliamente trabajada, sin embargo al tratarse del diagnóstico de dichas oscilaciones las metodologías utilizadas carecen de robustez o son difíciles de implementar en la práctica.

2.5. Detección de fallas en válvulas

Al hablar de fallas en válvulas, la adherencia estática (también conocida como **stiction**), la cual tiende a impedir que la válvula inicie su movimiento, es el problema más común en las válvulas de control neumáticas, las cuales son las más utilizadas en la industria. Esta adhesión hace que se presenten oscilaciones en el lazo de control, lo que reduce la productividad, disminuye la calidad en el producto final e incrementa el consumo de energía. Existen dos formas de modelar la adherencia estática de una válvula; la primera de ellas es una modelo matemático basado principios físicos como el propuesto por Muller [65], y el segundo es un modelo basado en datos que describa la relación entre la salida del controlador y la posición de la válvula, como es el caso del modelo propuesto por Choudhury et al [64]. Es de gran importancia establecer un buen modelo de este fenómeno dado que dicho modelo sería la referencia con la que se compararía el comportamiento real de una válvula de control. Debido que un modelo físico detallado tiene numerosos parámetros físicos desconocidos, en la práctica no sólo consume tiempo, sino también resulta inviable modelar una válvula de control con dicho modelo. Un modelo basado en datos, por otro lado, es útil, ya que tiene sólo unos pocos parámetros que son fáciles de identificar y fácil de entender. Para modelar la relación entre la salida del controlador y la posición de la válvula, se debe tener en cuenta el equilibrio entre la fuerza elástica, la presión de aire, y la fuerza de fricción. Esta relación puede ser descrita como se muestra en la figura 2.9. La línea discontinua indica los estados en los que la fuerza elástica y la presión del aire se equilibran; la salida del controlador y el cambio de posición de la válvula a lo largo de esta línea en una situación ideal sin ningún tipo de fricción.




Figura 2.9. Relación entre la salida del controlador y la posición de la válvula de control bajo la existencia de adhesión

Se han desarrollado varios métodos para la detección de stiction en las válvulas de control. Taha et al [66] menciona el *Bump Test*, el cual consiste en colocar el lazo de control con manual e incrementar en pasos pequeños la señal de salida del controlador hasta que haya un cambio significativo en la salida del proceso. Este método no resulta conveniente ni económico debido a que se corre el riesgo de alterar tanto la producción como la calidad del producto final. Choudhury [64] menciona que para las válvulas inteligentes, los datos del posicionador de la válvula usualmente están disponibles. Si la gráfica entre la posición de la válvula y la señal de salida del controlador tiene un patrón similar al del mostrado en la figura 2.9, se puede concluir la válvula sufre de adhesión. Sin embargo, más del 95% de las válvulas de control industriales no son válvulas inteligentes, debido al alto costo inicial y a los costos de mantenimiento, por lo cual Choudhury [64] propone realizar cambios en la ganancia del controlador; la presencia de adhesión en un lazo de control produce oscilaciones en el ciclo límite de la variable de proceso y la salida del controlador. Cambios en la ganancia del controlador produce cambios en la frecuencia y amplitud de dichas oscilaciones. Si la oscilación del ciclo límite se genera internamente dentro del lazo debido a la fricción estática de la válvula, un aumento en la ganancia del controlador aumentará la frecuencia de oscilación, mientras que si una oscilación límite entra en el lazo como una perturbación externa, un cambio en la ganancia del controlador no va a cambiar la frecuencia de la oscilación [64]. Por otro lado, Horch et al [67] presentan un método complejo para la detección de stiction mediante el cálculo de la

relación con la probabilidad logarítmica para múltiples modelos. Este método requiere conocimiento de las no linealidades de la planta y de los modelos de stiction y un filtro de Kalman extendido. Al igual que Horch et al [67], Stenman et al [68] propusieron un método para la detección de stiction difícilmente aplicable debido a su complejidad. Este método requiere la identificación de modelos de series de tiempo y realizar la optimización para obtener la relación con la distribución logarítmica. Por otro lado, Horch [69] detecta la fricción estática de la válvula mediante el análisis de la función de correlación cruzada (CCF) entre la salida del controlador y la salida de la planta. Se propuso que para una válvula con stiction se posee un desfase de entre 90° y 180° entre la salida del controlador y la salida del proceso para un controlador PI, mientras que un controlador agresivo u oscilaciones debidas a perturbaciones externas producen desfases de 180° , especialmente si hay saturación de en la salida del controlador. Otro método planteado Horch [69] es detectar las diferencias entre las formas de las señales cuando existe stiction y cuando el control es agresivo, utilizando distribuciones de probabilidad. Este método implica calcular la derivada de la variable controlada del lazo, filtrarla, y compararla con una referencia, bien sea mediante técnicas de ajuste no lineales (una para un modelo con stiction y otra para una controlador agresivo) o manualmente observando la forma de la gráfica. Singhal et al [79] también proponen un método semi-gráfico para detectar stiction. Básicamente propone que para plantas auto-reguladas, un controlador agresivo produce que el error se comporte aproximado a una sinusoidal, mientras que una válvula con stiction típicamente sigue un decaimiento exponencial. La razón de este comportamiento es que un lazo de control agresivo produce una respuesta continua (excepto cuando la señal se satura), mientras que una válvula con stiction resulta en una respuesta discontinua del proceso, tal y como se muestra en la figura 2.10.




Figura 2.10. Error del controlador para un lazo de control agresivo (izquierda) y para un lazo con una válvula con stiction (derecha)

El método propuesto en [79] analiza las áreas antes y después de un pico en el error; si la relación entre estas dos áreas es cercano a uno, las oscilaciones se deben a un lazo de control agresivo, mientras que si esta relación es mayor a la unidad, las oscilaciones se pueden atribuir a una válvula defectuosa (o a una perturbación periódica externa, por se deben realizar técnicas de detección de oscilaciones en las perturbaciones o realizar sobremando en el controlador e identificar continúan las oscilaciones, de esta forma se puede saber si las oscilaciones se producen adentro del lazo o si son debidas a causas externas). En [80] también se mencionan las diferencias marcadas entre las gráficas del error para un lazo de controla agresivo y un lazo con una válvula con stiction. Por otro lado, Choudhury et al [81] propone detectar stiction mediante la identificación de los componentes no-Gaussianos y no-lineales de la señal. Realizaron las simulaciones a partir del modelo propuesto en [64], al igual que detectaron no-linealidades en datos industriales reales. Hay que tener en cuenta que este método separa entre no-linealidades del proceso (grupo 1) o a stiction, zonas muertas e histéresis (grupo 2), por lo cual no discrimina la presencia de stiction sino el efecto combinado del grupo 2, lo cual puede ser beneficiosos si el objetivo es identificar si la válvula de control esta defectuosa y no directamente en la causa del defecto.

2.5.1. Métodos para la compensación de stiction en válvulas de control

La solución definitiva al problema de stiction es revisar y reparar la válvula. Sin embargo esta solución no puede ser considerada como la primera opción, ya que parar el proceso y aislar las válvulas de control para el mantenimiento no es económico. Por lo tanto, cuando el mantenimiento no está disponible, se deben considerar métodos de compensación. En la siguiente sección, se examinarán algunos algoritmos de compensación existentes. A diferencia de la detección o métodos de cuantificación, los algoritmos para compensar la fricción estática son relativamente escasos.

2.5.1.1. Knocker

Este método fue presentado por Choudhury [82]. La idea básica tras este método es agregar una señal pre diseñada a la salida del controlador, y de esa forma minimizar las fluctuaciones de la salida del proceso. El diagrama de bloques de esta metodología se presenta en la figura 2.11.




Figura 2.11. Diagrama de bloques para un lazo de control feedback con un knocker

La señal adicional está compuesta por una secuencia de pulsos con amplitud, ancho y tiempo entre dos pulsos consecutivos constantes. El signo de esta señal es mismo que la dirección de cambio en la señal de salida del controlador. Este compensador elimina las oscilaciones inducidas por la fricción de la variable de proceso. Sin embargo, como resultado de esta compensación, el vástago de la válvula se mueve más rápido e incluso más amplio que antes. El movimiento adicional de la válvula aumenta la tasa de daño, teniendo en cuenta lo significativa que es la fricción entre el vástago de la válvula y el empaque sellado. Independientemente, el método mencionado se considera como una solución a corto plazo para el problema de la fricción estática.

2.5.1.2. Refuerzo constante

Este método fue propuesto por Lakshminarayanan [83]. La idea tras este método es similar al propuesto por Choudhury [82], con la diferencia que la señal adicional no tiene forma de pulso. Los autores sugirieron un valor constante en magnitud, con el signo del cambio en la señal del controlador ($\alpha_k = a_{cr} * \text{sign}(\Delta m)$). De manera similar al método anterior, este método tampoco puede evitar movimientos adicionales de la válvula, de hecho, ese método proporciona una solución para mover el vástago de la válvula cuando se encuentra atascada, y generalmente se olvida de la etapa de movimiento de la válvula.

2.5.1.3. Filtrado de la señal retroalimentada

Este método fue propuesto Halimi et al [84]. Básicamente consiste en corregir la señal de salida del controlador, utilizando el filtro de la señal de salida del proceso, tal y como se muestra en la figura 2.12. Aunque la estructura y el orden del filtro no han sido elaborados por los autores, se afirma que este método reduce eficazmente las oscilaciones de hasta 75%.




Figura 2.12. Diagrama de bloques para un lazo de control feedback con compensación vía filtro de la señal de salida.

2.5.1.4. Compensador de dos movimientos

Este método fue propuesto por Srinivasan et al [85]. En este método, se centra en mantener la válvula en su posición de estado estable, correspondiente al setpoint. Para lograr este objetivo, por lo menos dos movimientos son necesarios por el vástago de la válvula con direcciones opuestas. La razón es que, incluso después de ajustar la señal de salida del controlador en el valor de estado estacionario, la válvula no se localizará necesariamente en la posición deseada. Las señales requeridas para producir tales movimientos deben tener magnitudes suficientemente grandes como para superar la fuerza de fricción. Asimismo, no debe ser demasiado grande para saturar la válvula.

2.5.1.5. Compensación vía sintonía del controlador

El método fue propuesto por Mohammad [86] utilizando el criterio de estabilidad planteado en [87]. Básicamente propone que un sistema $n \times n$ va a oscilar con una frecuencia w y magnitudes A_1, \dots, A_p ($p \leq n$), si se cumple que $\det(H) = 0$, donde H se define como:

$$H = \begin{bmatrix} D_1 & E_{1,2} & \cdots & E_{1,n-1} & E_{1,n} \\ E_{2,1} & D_2 & \cdots & E_{2,n-1} & E_{2,n} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ E_{n-1,1} & E_{n-1,2} & \cdots & D_{n-1} & E_{n-1,n} \\ E_{n,1} & E_{n,2} & \cdots & E_{n,n-1} & D_n \end{bmatrix}$$

$$D_i = 1 + G_{ii}(jw)G_i^C(jw)N_i(A_i)$$

$$E_{i,k} = 1 + G_{ik}(jw)G_k^C(jw)N_k(A_k)$$

En las ecuaciones mencionadas, G_{ij} es la función de transferencia entre la j^{th} entrada y la i^{th} salida, $N_i(A_i)$ es una función que describe al stiction en el i^{th} lazo y A_i es la magnitud de la entrada armónica a la válvula defectuosa de este lazo. Además, G_i^C representa al controlador utilizado en el i^{th} lazo. [86] enfocó su estudio en la relación numérica entre los valores de los parámetros de un controlador tipo PID con modos proporcional y proporcional-integrativo, con las características de las oscilaciones presentes en un lazo de control con proceso autorregulado y procesos integrantes.

3. DETECCIÓN TEMPRANA DE FALLAS UTILIZANDO VARIABLES DE LAZOS DE CONTROL

La detección temprana de fallas en procesos industriales permite la oportuna intervención y recuperación de la condición normal del proceso. Cuando una condición atípica ocurre, los métodos de detección de fallas convencionales no distinguen atributos típicos o específicos de los procesos de origen al momento de analizar la ocurrencia de la falla. Utilizando variables específicas de los lazos de control se puede obtener información de la dinámica del proceso que no se podría obtener únicamente con la información de los sensores. En este capítulo se presenta una metodología de detección de fallas con fin específico: detección de problemas en la válvula de control. Esta metodología utiliza un algoritmo convencional de PCA sobre las variables del lazo de control. Conjuntamente, se apoya en un modelo basado en lógica difusa de una válvula de control que sufre de fricción estática; de esa forma se logra diferenciar si la fuente de falla se debe a la sintonía del controlador o a problemas en la válvula de control. Finalmente se presenta el desarrollo de un conjunto de ecuaciones útiles para identificar la fuente de una falla en el espacio residual.

3.1. Análisis de componentes principales

Las técnicas de detección de fallas basadas en datos históricos han adquirido gran popularidad en los últimos años debido a la complejidad de los procesos industriales y a la cantidad de instrumentación con la que se cuenta actualmente. La confiabilidad de este tipo de métodos depende de la calidad de los datos tomados, los cuales se utilizan para describir estadísticamente el comportamiento del proceso. Como regla general, en este tipo de métodos se confía en la repetitividad las propiedades estadísticas, como la media y la varianza, para una misma condición operación, lo cual implica que las desviaciones significativas de alguna de estas propiedades son evidencia estadísticamente suficientes para afirmar la presencia de una falla [15].

El análisis de componentes principales (PCA) es una técnica de reducción dimensional multivariable basada en datos del proceso, la cual puede ser utilizada para la detección de fallas. Utilizándolo como método de detección, el algoritmo convencional de PCA puede dividirse en dos etapas: entrenamiento y detección; se recomienda también, que antes de cada etapa se realice un pre-tratamiento de los datos, el cual a su vez se divide en tres partes: remoción de variables, remoción de puntos atípicos (outliers) y auto-escalamiento de datos.

Remoción de variables y outliers

Los procesos industriales suelen estar altamente instrumentados, por este motivo, algunos de los datos tomados pueden ser redundantes, no aportar información significativa al comportamiento del proceso, o provenir de sensores defectuosos; esto puede causar que existan observaciones linealmente dependientes. Por tal, las variables que cumplieran con alguna de las condiciones arriba expuestas, se eliminan del set de datos que se va a utilizar para el monitoreo (remoción de variables). La segunda etapa del pre-tratamiento de datos, remoción de outliers, tiene como finalidad remover datos atípicos del set de entrenamiento, de esa forma se evita alterar las propiedades estadísticas del set de datos. Finalmente, es común encontrar en el set de datos variables que difieran considerablemente en su orden de magnitud (Temperaturas vs concentración, por ejemplo), debido a este se hace necesario un proceso de autoescalamiento.

Autoescalamiento

El autoescalamiento consiste en la estandarización de las observaciones de las variables del proceso. Matemáticamente el proceso que se realiza es el siguiente: Sea $X \in \mathbb{R}^{n \times m}$ una representación matricial de las m variables con n observaciones en el tiempo,

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix}$$

De esta forma, cada columna de la matriz representa una variable del proceso y cada fila representa una observación en el tiempo.

La estandarización de los datos se realiza restando a cada columna su media \bar{x}_i , y dividiendo dicha diferencia por la desviación estándar s_i de cada columna; ambas calculadas utilizando las n observaciones de cada columna del set de entrenamiento. Si bien estas operaciones pueden realizarse utilizando ciclos *for*, computacionalmente es más ventajoso trabajar con operaciones matriciales. Definimos $b \in \mathbb{R}^{m \times 1}$ como el vector de medias y $S_x \in \mathbb{R}^{m \times m}$ como la matriz de desviaciones, las cuales almacenan la información estadística de la siguiente manera:

$$b = [\bar{x}_1^{(0)} \ \bar{x}_2^{(0)} \ \dots \ \bar{x}_m^{(0)}]^T \quad S_x = \begin{bmatrix} s_1 & 0 & \dots & 0 \\ 0 & s_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & s_m \end{bmatrix}$$

De esta forma, se puede definir realizar el autoescalamiento como una operación matricial de acuerdo a la siguiente expresión:

$$X_{as} = (X - I_n \cdot b^T) \cdot S_x^{-1}$$

donde,

$$I_n = [1 \ 1 \ \dots \ 1]^T \in \mathbb{R}^{n \times 1}$$

Una vez autoescalados los datos, se obtiene un paquete de datos donde cada columna tiene media cero y varianza unitaria, de esta forma se evita que las variables de mayor magnitud sesguen las respuesta del estadístico y se acondiciona la matriz.

Etapas de entrenamiento

Una vez realizado el autoescalamiento se puede proceder a realizar la etapa de entrenamiento del método. Esta etapa consiste en obtener los vectores de carga y sus autovalores asociados, los cuales describen las direcciones de máxima variabilidad del set de datos. Ambos parámetros pueden obtenerse a partir de la matriz de covarianza de la muestra, la cual se define como:

$$S = \frac{1}{n-1} X_{as}^T X_{as}$$

donde, n es el número de muestras y X_{as} es el set de datos de entrenamiento previamente autoescalado. Para hallar los valores propios o autovectores de S se realiza una descomposición espectral de la misma:

$$S = V\Lambda V^T$$

En donde Λ ,

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_m \end{bmatrix} \in \mathbb{R}^{m \times m}$$

Es una matriz diagonal que contiene a los autovalores de S , mientras que $V = [V_1 \ V_2 \ \dots \ V_m] \in \mathbb{R}^{m \times m}$ es una matriz que contiene en cada columna el autovector correspondiente al autovalor ubicado en la misma columna de la matriz Λ .

Utilizando las matrices obtenidas se puede transformar la matriz X_{as} compuesta de variables correlacionadas en un conjunto de variables no correlacionadas $Y \in \mathbb{R}^{n \times m}$ utilizando la siguiente expresión:

$$Y = XV$$

De tal manera que cada columna de la matriz represente una variable no correlacionada del proceso. Para esta matriz se cumple que la varianza de cada una de sus columnas es igual al autovalor λ_i de Λ [15], es decir:

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_m \end{bmatrix} \cong \begin{bmatrix} s_1^2 & 0 & \dots & 0 \\ 0 & s_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & s_m^2 \end{bmatrix}$$

Si se desea capturar la variabilidad de los datos y a la vez que se minimiza el efecto del ruido, se puede optar por truncar las matrices $V \in \mathbb{R}^{m \times m}$ y $\Lambda \in \mathbb{R}^{m \times m}$ a las primeras " a " columnas de la matriz V , y a las primeras " a " filas y columnas de la matriz Λ , quedando de la forma:

$$V \in \mathbb{R}^{m \times a} \quad \Lambda \in \mathbb{R}^{a \times a}$$

a se conoce como el número de componentes principales, y este se puede calcular utilizando la regla de Kaiser. Esta afirma que un paquete de datos de media cero y varianza unitaria se considera como ruido

blanco, por lo cual todo autovalor menor o igual a uno, debe considerarse como ruido y debe ser descartado. Las matrices V y Λ , al igual que el número de componentes principales a , son las salidas de la etapa de entrenamiento.

Etapas de monitoreo

En la etapa de monitoreo se utilizan las matrices de obtenidas en la etapa de entrenamiento para calcular los estadísticos de prueba y el número de componentes principales para determinar los umbrales de detección. En primer lugar, se utilizan las medias y varianzas del set de entrenamiento para autoescalar las observaciones, las cuales están correlacionadas entre ellas. Se puede transformar una observación $x = [x_1 \ x_2 \ \dots \ x_m]^T$ de variables correlacionadas en un conjunto de variables no correlacionadas $y = [y_1 \ y_2 \ \dots \ y_m]^T$ por medio de la operación:

$$y = V^T x$$

Una vez se tienen las variables sin correlación espacial entre ellas, se puede lograr que el conjunto de variables tenga varianza unitaria al dividir por su desviación estándar:

$$z = \Lambda^{-1/2} V^T x$$

de forma que tal que cada observación transformada queda de la forma:

$$z = \begin{bmatrix} \frac{y_1}{s_1} & \frac{y_2}{s_2} & \dots & \frac{y_m}{s_m} \end{bmatrix}$$

Finalmente, se puede calcular el estadístico de Hotelling T^2 de cada observación a partir de z así,

$$T^2 = z^T z$$

donde T^2 es el cuadrado de la norma-2 de un vector de observaciones escalado a partir de su media;

$$T^2 = \frac{y_1^2}{s_1^2} + \frac{y_2^2}{s_2^2} + \dots + \frac{y_m^2}{s_m^2}$$

El umbral de detección para el estadístico T^2 se calcula a partir de la cantidad de datos en el set de entrenamiento y de la cantidad de componentes principales:

$$T_{\alpha}^2 = \frac{a(n-1)(n+1)}{n(n-a)} F_{\alpha}(a, n-a)$$

Las observaciones correspondientes a los $m - a$ menores autovalores puede ser monitoreado mediante el estadístico Q , también conocido como SPE (Squared Prediction Error). Para el cálculo de este estadístico, primero de define:

$$\mathbf{r} = (I - VV^T)\mathbf{x}$$

La matriz V , antes de la remoción de sus últimas $m - a$ columnas, es una matriz ortogonal, lo cual indica que $VV^T = I$; una vez removidas las columnas se tiene que $VV^T \cong I$, por lo cual \mathbf{r} es un vector de residuales, o una proyección de la observación \mathbf{x} en el espacio residual. Teniendo esto en cuenta, el estadístico Q , calculado como sigue:

$$Q = \mathbf{r}^T \mathbf{r}$$

es la suma de cuadrados de los residuales de la observación. El umbral de detección para el estadístico Q viene dado por:

$$Q_{\alpha} = \theta_1 \left[\frac{h_0 c_{\alpha} \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{1/h_0}$$

dónde:

$$\theta_i = \sum_{j=a+1}^n \sigma_j^{2i}$$

$$h_{0k+1} = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2}$$

y c_{α} es la desviación normal correspondiente al nivel de confianza $(1 - \alpha)$. La salida de la etapa de monitoreo es la comparación de los estadísticos con sus respectivos umbrales, afirmando la ocurrencia de una falla si cualquiera de los estadísticos supera su umbral.

3.2. Incorporación de las variables del lazo de control al análisis de componentes principales

El análisis de componentes principales basa su metodología en la suposición de que las variables del set de datos se encuentran correlacionadas entre ellas. Es normal encontrar en la práctica que entre dichas variables existan direcciones de mayor variación, o ejes principales, tal y como se muestra en la figura 3.1. El hecho de que el eje de mayor variación se encuentre con una inclinación indica que las variables están correlacionadas, y todo dato que se localice dentro de esta elipse se considera como condición normal de operación.




Figura 3.1. Ilustración grafica de la covarianza de variables correlacionadas

Un error común al momento de seleccionar los datos para el monitoreo del proceso, es tomar datos en estado estable de operación. Se podría pensar que el estado estable, al ser la condición deseada del proceso, debería ser el set de datos que se debe utilizar para el entrenamiento del método de detección de fallas, sin embargo esta decisión causaría un estadístico de prueba muy sensible, principalmente a perturbaciones. En un lazo de control es común encontrar perturbaciones, estas le dan sentido a la presencia de una estrategia de control, por ese motivo, al caracterizar el proceso en estado estable se estaría implicando que cualquier perturbación que ocurra en el proceso sea considerada como una falla del proceso.

Una alternativa propuesta por Russel et al [15] es la caracterización de las perturbaciones como distintos estados de operación, tal y como se muestra en la figura 3.2.




Figura 3.2. Distintos estados de operación del lazo de control

En la figura 3.2 se muestran tres elipses, representando cada una de las condiciones de operación del proceso: estado estable y dos perturbaciones no interactuantes. Utilizando este esquema, se dice que una observación se encuentra en condición normal de operación si se encuentra dentro de cualquiera de las elipses identificadas. Si bien como concepto esta propuesta es prometedora, en la práctica resulta muy difícil identificar el espacio de operación de cada perturbación, principalmente porque no todas las perturbaciones son medidas y existen interacciones entre ellas. Si existen k posibles perturbaciones, se necesitarían identificar 2^k condiciones de operación (k perturbaciones y 2 posibles estados de la perturbación: presente y ausente), en las cuales se cubre el estado estable, las perturbaciones y todas las posibles interacciones entre ellas. Considerando la cantidad de variables y de perturbaciones que existen en una planta industrial, resulta impráctico identificar cada condición de operación como se sugiere en la literatura [15].

En la figura 3.3 (a) se muestran las 16 posibles condiciones de operación de un lazo de control con 4 perturbaciones. Identificar la existencia de cada una de ellas resulta complicado en la práctica, sin embargo, se puede tener suficiente información histórica como para tener un área de confianza en la cual usualmente se mantengan las variables del

proceso sin tener que identificar cada estado independientemente, como se muestra en la figura 3.3 (b).




Figura 3.3. (a) Espacio de trabajo de un lazo de control con 4 perturbaciones. (b) Región considerada condición normal de operación

Una desventaja inevitable al tomar los datos de la manera propuesta es el aumento en la varianza de los datos, lo cual se ve reflejado en la tasa de falsas alarmas del método. Se recuerda que estadístico T^2 se calcula a partir de:

$$T^2 = z^T z \quad z = \Lambda^{-1/2} V^T x$$

y las matrices Λ y V provienen de la matriz de covarianza de los datos, por lo cual, un conjunto de datos de mayor varianza producirá que el estadístico de prueba tenga mayor varianza. Por otro lado, el umbral del estadístico depende únicamente de la cantidad de componentes principales y del número de datos:

$$T_\alpha^2 = \frac{a(n-1)(n+1)}{n(n-a)} F_\alpha(a, n-a)$$

por lo cual, para un mismo tamaño muestral y un mismo proceso, se tendría una mayor tasa de falsas alarmas si se utiliza un solo set de entrenamiento con variables perturbadas que varios sets con distintas condiciones de operación. Dicho comportamiento se puede observar en la figura 3.4, donde se muestra el comportamiento del estadístico T^2 para cada caso. Un comportamiento análogo se presenta en el estadístico Q .




Figura 3.4. (a) Estadístico T^2 para datos en estado estable. (b) Estadístico T^2 para datos perturbados

Las variables de los lazos de control se encuentran normalmente perturbadas y/o en estado transitorio, por tal motivo el estadístico de prueba no va a confundir una perturbación con una falla, sin embargo son datos con una alta variabilidad que eventualmente se verá reflejado en un incremento en la tasa de falsas alarmas del método.

Para solucionar el problema de las falsas alarmas, se propone realizar el promedio ponderado (exponencialmente) a cada observación de los estadísticos de prueba, y de esta forma transformarlos en nuevos estadísticos (estadísticos EWMA) que incluyan la información de las observaciones pasadas para el cálculo de la actual. De esta forma, cambios súbitos en el estadístico serán compensados por el peso de las anteriores observaciones. Para la transformación de los estadísticos, se utilizan las siguientes ecuaciones:

$$\kappa_i = \lambda T_i^2 + (1 - \lambda) \kappa_{i-1} \quad \phi_i = \lambda Q + (1 - \lambda) \phi_{i-1}$$

donde $0 < \lambda \leq 1$ es una constante de ponderación, que indica cuanto peso se le da al nuevo dato y cuanto peso se le da a cada una las observaciones anteriores; el dato actual pesa λ , y los datos anteriores pesan $\lambda(1 - \lambda)^j$, donde el exponente j es cuantas observaciones por detrás de la actual se encuentra el dato. Por otro lado,

$$\kappa_0 = \text{media}(T_e^2) \quad \phi_0 = \text{media}(Q_e)$$

donde T_e^2 y Q_e son los vectores con los estadísticos calculados a partir del set de entrenamiento.

Una vez transformados los estadísticos es necesario recalcular los umbrales de detección. Los umbrales de cada estadístico se calculan como si se tratara del umbral de una técnica de detección de fallas univariada: L desviaciones estándares por encima de la media del estadístico [20]:

$$\kappa_u = \kappa_0 + L_\kappa \sigma_\kappa \quad \phi_u = \phi_0 + L_\phi \sigma_\phi$$

Si cada observación del estadístico es independiente y aleatoria con varianza σ , entonces la varianza del nuevo estadístico (σ_κ y σ_ϕ), se puede calcular a partir de:

$$\sigma_{\kappa,\phi}^2 = \sigma_{T^2,Q}^2 \left(\frac{\lambda}{2-\lambda} \right)$$

por lo que los umbrales de detección quedan de la siguiente manera:

$$\kappa_u = \kappa_0 + L_\kappa \sigma_{T^2} \sqrt{\left(\frac{\lambda}{2-\lambda} \right)} \quad \phi_u = \phi_0 + L_\phi \sigma_Q \sqrt{\left(\frac{\lambda}{2-\lambda} \right)}$$

De esta forma, se dice que una falla ha ocurrido si alguno de los estadísticos EWMA supera su umbral, y se ignora si los estadísticos originales superan su umbral. Para definir completamente los estadísticos y sus umbrales, es necesario determinar los valores de λ y L para cada estadístico. En [20] se presenta la carta de control EWMA, ahí se sugiere que la constante de ponderación varíe de $0.05 \leq \lambda \leq 0.25$, y que L se encuentre en los alrededores de las 3 unidades. La selección de estos parámetros va a influir directamente en la capacidad de detectar las fallas, por tal motivo su selección no puede ser arbitraria. En la siguiente sección se presenta el diseño del experimento realizado para determinar los parámetros óptimos del estadístico, dadas unas condiciones en el conjunto de entrenamiento.

3.2.1. Ecuaciones de sintonía para el estadístico EWMA

Se realizó un diseño experimental buscando determinar los parámetros óptimos para la transformación de los estadísticos. Con esto se desea obtener un set de ecuaciones que relacionen las características de los estadísticos de prueba con los valores de λ y L óptimos. Los factores escogidos para describir al estadístico original fueron su varianza σ^2 , y la distancia entre su media y el umbral calculado ($\delta = \kappa_0 - T_\alpha^2$); por otro lado, las variables de respuesta escogidas fueron: El tiempo de adelanto en la detección, definido como la diferencia entre el tiempo que demora el estadístico original en detectar una falla incipiente y el tiempo que demora el estadístico EWMA en detectar la misma falla, y la tasa de falsas alarmas.

Al usar estas variables de respuesta se busca disminuir la tasa de falsas alarmas ocasionadas por la alta variabilidad de los estadísticos, mientras que se maximiza en lo posible la capacidad de detectar fallas incipientes, es decir, aquellas que se caracterizan por un desarrollo paulatino y lento. Se realizó un experimento factorial 3^2 sin replicas para ajustar los factores anteriormente presentados a los valores óptimos de λ y L , los cuales se obtuvieron a partir de un experimento intermedio entre ellos y las variables de respuesta. Este experimento intermedio fue un experimento factorial 3^2 con cuatro replicas, el cual se realizó para cada una de las nueve corridas del experimento principal, lo cual da un total de 324 corridas. En la tabla 3.1 se muestran los factores y sus niveles.

Factores experimentales	Niveles		
	Bajo	Medio	Alto
σ^2	1	30.5	60
δ	1	8	15
λ	0.05	0.125	0.2
L	1	3	6

Tabla 3.1. Factores experimentales y niveles de operación

Para determinar los valores de λ y L óptimos se realizó un proceso de optimización multivariable utilizando los datos obtenidos en cada corrida del experimento intermedio. Para la optimización se utilizó el método de la “función de deseabilidad”, en el cual se calcula el índice de deseabilidad de cada variable de repuesta utilizando la siguiente ecuación:

$$d_k = \begin{cases} 0 & \text{if } y_k \leq y_{min} \\ \left(\frac{|y_k - y_u|}{y_{max} - y_{min}} \right)^{0.1} & \text{if } y_{min} \leq y_k \leq y_{max} \\ 1 & \text{if } y_k \geq y_{max} \end{cases}$$

En donde d_k es el índice de deseabilidad, y_{min} y y_{max} son los límites de la región de búsqueda, y_k es el valor deseado la k -ésima respuesta, y y_u es el valor mínimo o máximo que puede tomar la variable de respuesta si se desea maximizar o minimizar respectivamente. Una vez cada índice de deseabilidad es calculado, el siguiente paso es calcular el índice de deseabilidad compuesto, utilizando la siguiente ecuación:

$$D_G = [d_1 \times d_2 \times \dots \times d_k]^{\frac{1}{k}}$$

Finalmente se máxima D_G para obtener la respuesta más “deseable”. Utilizando este método implícitamente se le está dando igual importancia a

cada variable de respuesta. Los resultados óptimos para cada corrida se presentan en la tabla 3.2.

	σ^2	δ	λ	L
1	30,5	1	0,05	4,27632
2	60	8	0,05	4,67352
3	60	1	0,05	4,06159
4	60	15	0,05	5,04617
5	1	15	0,05	5,28493
6	1	8	0,05	5,04265
7	30,5	8	0,05	4,77885
8	1	1	0,05	4,62918
9	30,5	15	0,05	5,0301

Tabla 3.2. Valores óptimos de λ y L para cada corrida experimental

De la tabla anterior se observa que el valor óptimo para λ fue el límite inferior de cada corrida, por lo cual se tomará este valor para transformar a los estadísticos, por otro lado, se realizó un modelo de regresión para el valor óptimo de L del cual se obtuvo la siguiente ecuación ($R^2_{adj} = 0,9627$):

$$L = 4.534 + 0.04\delta + \log\left(\frac{\sigma^2}{\delta}\right)$$

Para verificar la idoneidad del modelo de regresión, se comprueban los tres criterios de idoneidad: Significancia del modelo, significancia de los coeficientes y residuales sin tendencia. En la tabla 3.3 se muestra la tabla ANOVA del modelo, donde se aprecia que el P-value es menor que $\alpha = 0.05$, por lo cual se dice que el modelo es significativo,

ANÁLISIS DE VARIANZA					
Fuente	dof	SS	MS	F	P - value
Regresión	2	1,221851	0,610925	104,4813	2,17E-05
Residuos	6	0,035083	0,00584		
Total	8	1,256934			

Tabla 3.3. Tabla ANOVA para el modelo de regresión

En la tabla 3.4 se presenta el resumen del análisis de cada uno de los coeficientes de regresión del modelo. Utilizando el nuevamente el P-value como criterio de decisión, se afirma que los coeficientes del modelo son significativos.

Variable	Intercepto	δ	$\log(\sigma/\delta)$
Coefficientes	4,5333	0,0387	-0,2172
P - value	2,31E-10	0,0000305	0,000514

Tabla 3.4. Resumen del análisis de los coeficientes de regresión

Finalmente, en la figura 3.5 se muestra la gráfica de los residuales donde no se aprecia una tendencia marcada en los residuales.




Figura 3.5. Gráfico de los residuales para cada factor

En la figura 3.6 se muestra la comparación de los comportamientos de los estadísticos T^2 y Q , con sus contrapartes κ y ϕ respectivamente. Las gráficas se obtuvieron con los datos de uno de los casos de estudio presentados en el capítulo 5, en el cual se presentara con más detalle los datos utilizados y los resultados obtenidos.

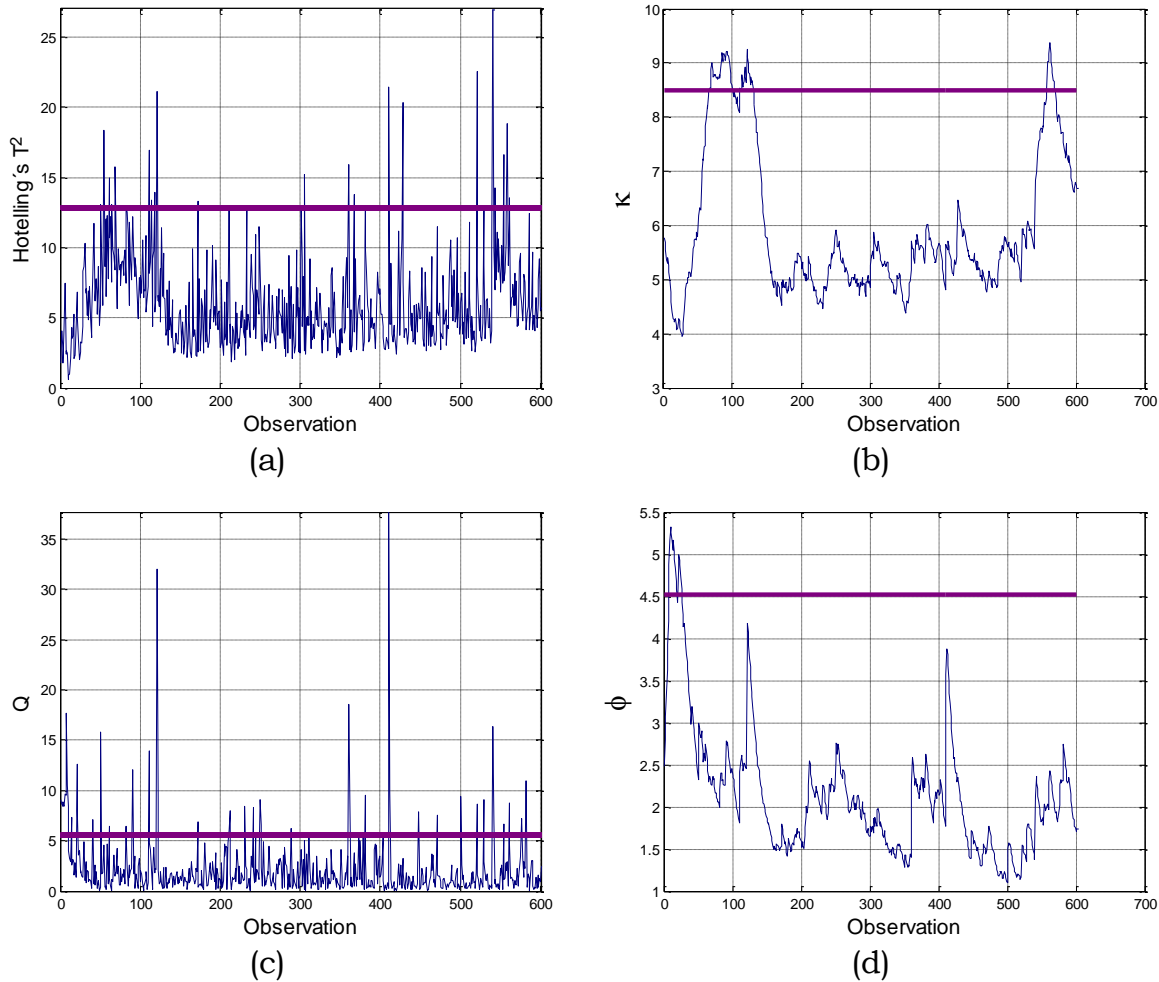


Figura 3.6. (a) Estadístico T^2 para datos perturbados. (b) Estadístico κ con $\lambda = 0.05$ y $L = 4.7$ (c) Estadístico Q para datos perturbados. (d) Estadístico ϕ con $\lambda = 0.05$ y $L = 4.7$.

A medida que se resta importancia a capacidad de anticipar una falla incipiente y se le da más peso a las falsas alarmas, el valor óptimo de λ tiende a aumentar. Con esto en mente, se recomienda utilizar $\lambda = 0.05$ si el propósito del método es detectar fallas incipientes (relacionadas con envejecimiento del proceso; su detección temprana permitiría mejorar las actividades de manteniendo predictivo), y $\lambda = 0.2$ si la principal preocupación es detectar fallas súbitas (poseen una dinámica paso escalón y su detección temprana es vital en sistemas donde fallas de este tipo traen consigo consecuencias catastróficas). En la figura 3.7 se muestra una comparación del comportamiento de los estadísticos en cada caso.

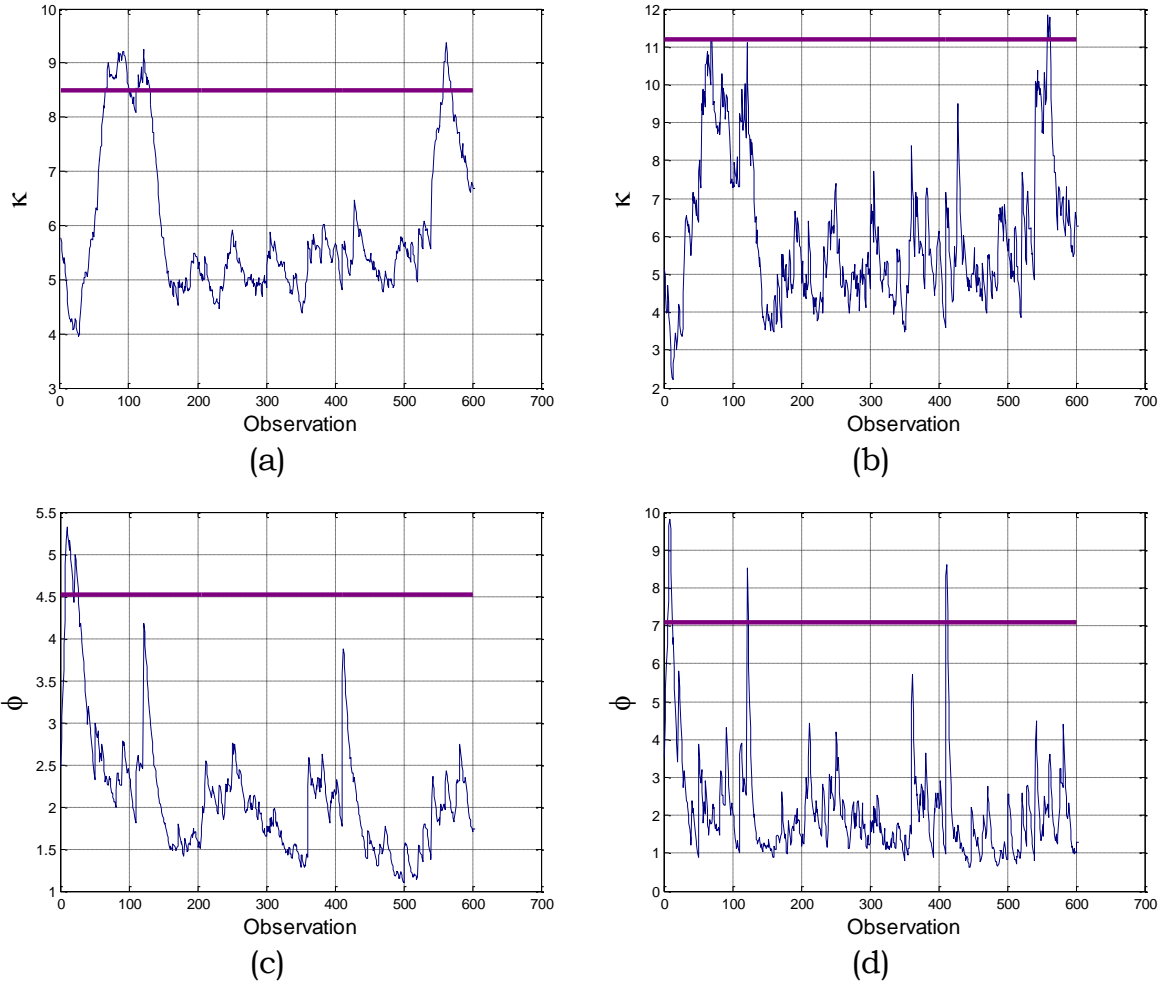


Figura 3.7. (a) Estadístico κ con $\lambda = 0.05$ y $L = 4.7$ (b) Estadístico κ con $\lambda = 0.2$ y $L = 4.7$
(c) Estadístico ϕ con $\lambda = 0.05$ y $L = 4.7$ (d) Estadístico ϕ con $\lambda = 0.2$ y $L = 4.7$

Utilizando las ecuaciones presentadas se soluciona la problemática de las excesivas falsas alarmas presentes en datos con mucha variación, y su utilización no se limita a variables de un lazo de control ya que trabajan directamente sobre el estadístico original, por lo cual pueden ser utilizadas para mitigar las falsas alarmas en cualquier escenario.

3.2.2. Variables escogidas para el monitoreo del proceso

El principal enfoque de esta investigación son los lazos de control instalados en procesos industriales, por lo cual las variables fueron escogidas pensando en estas aplicaciones. En la tabla 3.5 se muestran las variables escogidas para monitorear el proceso, las cuales incluyen señales y variables de proceso que siempre van a estar presentes en este tipo de lazos de control.

Variable	Concepto	Variable	Concepto
$m(t)$	Señal del controlador	$V_p(t)$	Porcentaje de apertura de la válvula
$\frac{dm(t)}{dt}$	---	$\frac{dV_p(t)}{dt}$	---
$m_p(t)$	Parte proporcional de la señal del controlador	$\Delta P(t)$	Caída de presión
$\frac{dm_p(t)}{dt}$	---	$c_d(t)$	Señal del sensor de la perturbación
$m_I(t)$	Parte integral de la señal del controlador	$\frac{dc_d(t)}{dt}$	---
$\frac{dm_I(t)}{dt}$	---	$e_m(t)$	Error de modelaje
$m_D(t)$	Parte derivativa de la señal del controlador	$K_c(t)$	Ganancia del controlador
$\frac{dm_D(t)}{dt}$	---	$\tau_I(t)$	Tiempo integral
$c(t)$	Señal del sensor	$\tau_D(t)$	Tiempo derivativo
$\frac{dc(t)}{dt}$	---	$EV_p^M(t)$	Error de modelaje de la válvula
$e(t)$	Error	$\int EV_p^M(t)$	Integral del error de modelaje de la válvula

Tabla 3.5. Variables del lazo de control seleccionadas para el monitoreo del proceso

A continuación se presenta la justificación de la inclusión de cada variable. $m(t)$ es la señal de salida del controlador, ella determina el porcentaje de apertura de la válvula de control. La inclusión de esta variable permite en primer lugar, detectar cambios en la ganancia del proceso, lo cual se ve en la relación en estado estable entre esta variable y la señal del sensor $c(t)$, y en segundo lugar, la relación dinámica entre esta variable y $c(t)$ permite determinar cambios en la constante de tiempo y en el tiempo muerto del proceso. Por otro lado, para procesos con baja ganancia las desviaciones en $m(t)$ son más apreciables que en $c(t)$ debido al efecto del controlador, por lo cual permitirá que se puedan detectar fallas de menor magnitud. Finalmente, para procesos con ganancias grandes, en los cuales $m(t)$ no varíe sustancialmente, se puede utilizar su información y la de $c(t)$ para determinar problemas en la sintonía del controlador; si la señal del controlador en procesos con ganancia grande se desvía sustancialmente de su valor en estado estable, la causa más probable es una sintonía demasiado agresiva.

Para controladores tipo PID, la señal de salida del controlador posee tres componentes: $m_p(t)$, $m_I(t)$ y $m_D(t)$, las cuales representan su parte proporcional, integral y derivativa respectivamente, las cuales se calculan a partir de las siguientes ecuaciones:

$$m_p(t) = K_c e(t) \quad m_I(t) = \frac{K_c}{\tau_I} \int e(t) dt \quad m_D(t) = -K_c \tau_D \frac{dc(t)}{dt}$$

en donde, K_c es la ganancia del controlador, τ_I es el tiempo integrativo, τ_D es el tiempo derivativo y $e(t)$ es el error del lazo de control. Si bien $m(t)$ contiene la información que transmite cada una de sus componentes, la inclusión de cada una de estas facilita el proceso de identificación de la falla, ya que cada una de ellas se afecta por fuentes diferentes. La parte proporcional detecta desviaciones inusuales de la variable de proceso de su valor deseado, la parte integral detecta las desviaciones en el desempeño del lazo (detecta si el lazo se hace más lento o agresivo), y la parte derivativa detecta cambios en la tendencia del proceso y el ruido de la señal transportada.

Por otro lado, $c(t)$ y $c_d(t)$, las señales de los sensores de la variable controlada y la principal perturbación respectivamente, se incluyen para tener variables con significado físico en el set de datos, las cuales sean directamente relacionables con el proceso. Estas variables son de importancia puesto que ellas son las que están relacionadas con la calidad del producto final. El error de modelaje $e_m(t)$ por su parte, se incluye para detectar los efectos de las perturbaciones no medidas y/o el envejecimiento del proceso. Los parámetros del controlador (K_c , τ_I y τ_D) puesto que uno de los objetivos de la investigación es compensar las fallas en el desempeño del lazo vía sintonía; variaciones muy grandes en estos parámetros indican que el proceso tuvo un cambio de condición de operación no esperado por la estrategia.

Finalmente, $V_p(t)$, $\Delta P(t)$ y $EV_p^M(t)$, se toman en cuenta para tener información del estado de la válvula. El 30% de los lazos de control presentan problemas de desempeño debido a fallas en la válvula de control, principalmente por la fricción estática [2,3]. El error de modelaje de la válvula y su integral tiene como propósito identificar la fricción estática presente en una válvula de control. Las derivadas de las variables arriba mencionadas se incluyen puesto que poseen información de la dinámica del lazo de control.

3.2.3. Modelo de una válvula de control con fricción estática basado en lógica difusa

Una de las variables incluidas en el set de datos es el error de modelaje de la válvula $EV_p^M(t)$, el cual está definida como:

$$EV_p^M(t) = V_p(t) - V_p^M(t)$$

donde, $V_p^M(t)$ es la posición predicha de la válvula a partir de un modelo. Esta variable tiene como finalidad detectar la fricción estática en la válvula de control, la cual es una de las principales causas de un mal desempeño del lazo de control; su detección temprana permite planeación de actividades correctivas bien sea mantenimiento de la válvula o re-sintonía del controlador.

Todas las válvulas de control sufren de fricción estática, y su efecto se hace más severo a medida que envejecen los actuadores. El comportamiento de una válvula con fricción estática es no lineal y seccionalmente continuo (existen puntos con derivadas no definidas), por lo cual, si dicho comportamiento se describe a través de métodos convencionales (funciones de transferencia, modelos CARMA o ARIMA), se obtendrá una alta tasa de falsas alarmas, o simplemente esta variable proporcionará información errónea del estado de la válvula.

Puesto que el comportamiento de una válvula de control ha sido ampliamente estudiado, se propone transformar dicho conocimiento en un modelo basado en lógica difusa que permita describir de manera adecuada las discontinuidades presentes en el actuador. Se utilizó el algoritmo lógico de Choudhury *et al* [64], como base y examinador del modelo.

La entrada al modelo de la válvula es la señal del controlador y su salida es el porcentaje de apertura de la válvula. Dentro del bloque hay tres etapas: dos etapas de escalamiento y una etapa intermedia de inferencia difusa. En la primera etapa de escalamiento se transforma a la señal del controlador en dos indicadores: el indicador de magnitud M_g , y el indicador de sentido, calculados a partir de las siguientes ecuaciones:


$$M_g = \frac{|m(t) - x_{ss}|}{S}$$

$$M_l = \text{sign}(m(t) - m(t-1)) * \text{sign}(m(t-1) - m(t-2))$$

en donde x_{ss} es el último valor en el que la válvula estuvo pegada y S es la banda de stiction (en cuanto por encima de x_{ss} debe estar $m(t)$ para iniciar el movimiento). Se dice que una válvula se encuentra pegada si $m(t)$ no supera la banda de stiction a partir del reposo, y si existe un cambio de dirección en el movimiento. Por tal la válvula de control va a estar pegada si $M_g < 1$ y/o $M_l \leq 0$.

El indicador de magnitud y el indicador de sentido son las entradas al sistema de inferencia difusa, junto con el indicador de estado I , el cual indica el estado de la válvula un periodo de muestreo anterior (1 se la válvula esta estática y 0 si está en movimiento); las salidas del bloque son el factor β , el cual indica cuánto cambio va a tener la válvula en cada periodo de muestreo, y el indicador de estado en el periodo de muestreo actual.

Se utilizaron funciones de pertenencia triangulares para relacionar a cada variable numérica con su variable difusa con cierto grado de pertenencia. Para M_g se definieron 2 valores lingüísticos que puede tomar su variable difusa: “No” y “Move”. Para M_l se definieron 3 valores: “Change”, “Rest” y “Straight”. Para I se definieron 2 valores: “Stick” y “Move”. Finalmente para β se definieron dos valores “No” y “Change”. Se utilizó un sistema de inferencia difuso (FIS) de Mamdani con 7 reglas base. En la figura 3.8 se presenta un resumen de la arquitectura del FIS.



System Valvula: 3 inputs, 2 outputs, 7 rules

Figura 3.8. Arquitectura del sistema de inferencia difusa.

En las figuras de la 3.9 a la 3.13 se muestran las funciones de pertenencia que relacionan a las variables naturales con su variable difusa, con cierto grado de pertenencia.




Figura 3.9. Valores lingüísticos y función de pertenencia para el indicador de magnitud




Figura 3.10. Valores lingüísticos y función de pertenencia para el indicador de sentido




Figura 3.11. Valores lingüísticos y función de pertenencia para el indicador de estado anterior (input)




Figura 3.12. Valores lingüísticos y función de pertenencia para el factor β




Figura 3.13. Valores lingüísticos y función de pertenencia para el indicador de estado actual (output)

En la tabla 3.6 se presentan las reglas utilizadas en el sistema de inferencia difusa.

SI			ENTONCES	
M_g	M_I	I_{OLD}	β	I_{NEW}
Move	Straight	Stick	Change	Move
Move	Straight	Move	Change	Move
No	Straight	Stick	No	Stick
Move	Change	Move	No	Stick
Move	Rest	Stick	Change	Move
Move	Rest	Move	No	Stick
No	Rest	Stick	No	Stick

Tabla 3.6. Reglas difusas usadas en el sistema de inferencia difusa.

El sistema de inferencia difusa calcula el valor de β , el cual se utiliza para calcular la señal efectiva del controlador $M_R(t)$ a partir de:

$$M_R(t) = x_{ss}\beta + (m(t) + J * \text{sign}(m_k - m_{k-1}))(1 - \beta)$$

en donde J es el offset de la válvula de control. Dependiendo de este parámetro se pueden modelar distintos tipos de adherencia (stiction):

- ❖ Si $S = 0$ y $J = 0$, se presenta una válvula sin fricción estática. Este caso para efectos prácticos no se consigue, sin embargo en las

válvulas de control nuevas el efecto del stiction es despreciable, asemejándose a este tipo de comportamiento.

- ❖ Si $S \neq 0$ y $J < 0$, en este caso la válvula no alcanzará el valor deseado, debido al undershoot presente.
- ❖ Si $S \neq 0$ y $J = 0$, en este caso produce un comportamiento de stiction puro, en el cual la válvula se mueve súbitamente hasta alcanzar el valor de la señal deseada.
- ❖ Si $S \neq 0$ y $J > 0$, en este caso, el movimiento es tan agresivo que la válvula tiene overshoot antes de alcanzar el valor deseado.

Finalmente, para calcular el porcentaje de apertura de la válvula se utilizan las siguientes ecuaciones dinámicas:

$$\text{válvula falla cerrada: } \tau_v \frac{dV_P^M}{dt} + V_P^M = \frac{M_R(t)}{100}$$

$$\text{válvula falla abierta: } \tau_v \frac{dV_P^M}{dt} + V_P^M = 1 - \frac{M_R(t)}{100}$$

donde τ_v es la constante de tiempo de la válvula. Este parámetro, junto con J y S , son los parámetros utilizados para identificar a la válvula instalada. Para obtener S se hace que la señal del controlador aumente paulatinamente en forma de rampa desde un \bar{m} hasta que se inicie el movimiento se inicie en m_{xs} . El parámetro S se estima como:

$$S = m_{xs} - \bar{m}$$

Para determinar τ_v y J se realiza un paso escalón Δm en la señal del controlador y se espera a que estabilice la posición de la válvula en V_{Pf} . El parámetro J se calcula como:

$$J = \frac{100(V_{Pf} - V_{Po}) - \Delta m}{100\Delta m}$$

y la constante de tiempo de la válvula se estima como:

$$\tau_v = \frac{3}{2}(t_2 - t_1)$$

donde t_1 es el tiempo en el que ocurre el 28.3% del cambio en la posición del actuador, y t_2 es el tiempo en el que ocurre el 63.2% del cambio en la posición del actuador. Desde la 3.14 a la 3.16 se muestra el desempeño del modelo difuso para cada uno de los casos de stiction presentados.




Figura 3.14. Desempeño del modelo difuso para una válvula de control falla cerrada con inercia despreciable ($S = 5$ y $J = 0$)




Figura 3.15. Desempeño del modelo difuso para una válvula de control falla cerrada con inercia despreciable ($S = 5$ y $J = 3$)





Figura 3.16. Desempeño del modelo difuso para una válvula de control falla cerrada con inercia despreciable ($S = 5$ y $J = -3$)


Utilizando el modelo propuesto se puede describir adecuadamente el comportamiento de la válvula de control. A medida que la fricción estática se hace más severa, el comportamiento de la válvula se alejará del comportamiento propuesto, de esta forma se puede detectar la presencia de stiction en la válvula.

3.3. Conjunto de ecuaciones para la identificación de fallas en el espacio residual


Uno de los objetivos de esta investigación es discernir si causa de un mal desempeño en el lazo de control es debido al controlador o al elemento final de control. Cuando las oscilaciones se deben a la válvula de control, lo más frecuente es que la válvula sufra de fricción estática severa [64]. Como se mencionó en la sección 3.2.3 esta falla se pretende detectar utilizando el error de modelaje de la válvula. Puesto que una falla puede ocurrir por distintos motivos, una vez detectada la falla es necesario identificar la fuente de su ocurrencia. En el set de datos existen variables como $m(t)$ y $c(t)$, las cuales tienen alta variabilidad y llevan consigo información de la tendencia del proceso, por lo cual, el $EV_p^M(t)$ será una variable que no aportará significativamente a los componentes principales, por tal motivo una falla en esta variable se verá relegada en el espacio residual (estadístico Q), tal y como se muestra en la figura 3.17.




(a)




(b)




(c)



(d)



(e)



(f)

Figura 3.17. Comportamiento de los estadísticos ante la presencia de stiction.
 (a) Estadístico T^2 para una válvula proporcional. (b) Estadístico Q para una válvula proporcional. (c) Estadístico T^2 para una válvula isopercentual. (d) Estadístico Q para una válvula isopercentual. (e) Estadístico T^2 para una válvula proporcional (stiction altamente desarrollado). (f) (Estadístico Q para una válvula proporcional (stiction altamente desarrollado))

En la figura 3.17 se muestra el comportamiento de los estadísticos ante un incremento de 0.007 en la banda de stiction cada unidad de tiempo. Se observa que el comportamiento de los estadísticos es independiente del tipo de válvula; el estadístico Q se sale de su límite de control, mientras que T^2 se mantiene. En la figura 3.17e se observa que si se deja desarrollar la falla el tiempo suficiente (1700 unidades de tiempo de diferencia), el estadístico T^2 empezará a salirse de control, esto ocurre cuando la adhesión es tan severa que la parte integral del controlador se sale de control; detectar la falla en este punto no es beneficioso para la integridad de la válvula ni para el desempeño del lazo de control.

Para identificar el motivo de la falla en el espacio residual, se desarrolla un set de ecuaciones que sean capaces de determinar la causa de la falta de control del estadístico Q , puesto que la literatura en este campo es limitada [15].

El estadístico Q es la suma de cuadrados de los residuales de cada observación en el tiempo, lo cual escrito de forma matricial se define como:

$$Q = \mathbf{r}^T \mathbf{r} \quad \mathbf{r} = (\mathbf{I} - \mathbf{V}\mathbf{V}^T)\mathbf{x}$$

en donde el vector $\mathbf{r} \in \mathbb{R}^{m \times 1}$ es la proyección de $\mathbf{x} \in \mathbb{R}^{m \times 1}$ en el espacio residual. Partiendo de esta definición se tiene que:

$$Q = [(\mathbf{I} - \mathbf{V}\mathbf{V}^T)\mathbf{x}]^T [(\mathbf{I} - \mathbf{V}\mathbf{V}^T)\mathbf{x}]$$

Utilizando la propiedad de la transpuesta de un producto $(\mathbf{A}\mathbf{B})^T = \mathbf{B}^T \mathbf{A}^T$ y la propiedad de la transpuesta de una suma $(\mathbf{A} + \mathbf{B})^T = \mathbf{A}^T + \mathbf{B}^T$, se tiene:

$$Q = [\mathbf{x}^T (\mathbf{I} - \mathbf{V}\mathbf{V}^T)^T] [(\mathbf{I} - \mathbf{V}\mathbf{V}^T)\mathbf{x}]$$

$$Q = [\mathbf{x}^T (\mathbf{I}^T - (\mathbf{V}\mathbf{V}^T)^T)] [(\mathbf{I} - \mathbf{V}\mathbf{V}^T)\mathbf{x}]$$

$$Q = [\mathbf{x}^T (\mathbf{I}^T - (\mathbf{V}^T)^T \mathbf{V}^T)] [(\mathbf{I} - \mathbf{V}\mathbf{V}^T)\mathbf{x}]$$

la matriz idéntica es una matriz simétrica por lo que $\mathbf{I}^T = \mathbf{I}$, por otro lado, la transpuesta es una función involutiva, por lo cual $(\mathbf{V}^T)^T = \mathbf{V}$. Considerando lo anterior se tiene que:

$$Q = \mathbf{x}^T (\mathbf{I} - \mathbf{V}\mathbf{V}^T) (\mathbf{I} - \mathbf{V}\mathbf{V}^T) \mathbf{x}$$

$$Q = \mathbf{x}^T \vartheta \mathbf{r}$$

en donde $\vartheta = \mathbf{I} - \mathbf{V}\mathbf{V}^T$ y $\mathbf{r} = (\mathbf{I} - \mathbf{V}\mathbf{V}^T)\mathbf{x}$, tal y como se definió anteriormente.

La matriz $\vartheta \mathbb{R}^{a \times a}$ es una matriz simétrica de la forma:

$$\vartheta = \begin{bmatrix} 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & 0 \\ \vdots & \vdots & \ddots & 1 & \vdots \\ 0 & 0 & \dots & 0 & 1 \end{bmatrix} - \begin{bmatrix} V_{11} & V_{12} & \dots & V_{1a} \\ V_{21} & V_{22} & \dots & V_{2a} \\ \vdots & \vdots & \ddots & \vdots \\ V_{m1} & V_{m2} & \dots & V_{ma} \end{bmatrix} \begin{bmatrix} V_{11} & V_{21} & V_{31} & \dots & V_{m1} \\ V_{12} & V_{22} & V_{32} & \dots & V_{m2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ V_{1a} & V_{2a} & V_{3a} & \dots & V_{ma} \end{bmatrix}$$

Conociendo esta estructura se puede demostrar que cada posición de la matriz tiene la siguiente estructura:

$$\vartheta_{i,j} = I_{i,j} - \sum_{k=1}^a V_{ik}V_{jk}$$

Una vez reescrito el estadístico, y conociendo cada termino de las matrices que producen al estadístico Q , es posible cuantificar la contribución de cada variable a los $l < a$ componentes de Q causantes del comportamiento atípico del estadístico. El procedimiento propuesto es el siguiente: una vez detectada una violación en el estadístico, se calculan las componentes de Q causantes de la falla, por ejemplo, aquellos con $r_i^2 > 9\sigma_i^2$ (aquellos que difieran en 3 desviaciones estándares de su media). Una vez identificados estos componentes, se calcula la contribución de cada variable x_j a cada componte r_i fuera de control utilizando la ecuación propuesta:

$$cont_{i,j} = \frac{r_i \vartheta_{i,j} (x_j - \mu_j)}{\sigma_j} \quad \vartheta_{i,j} = \begin{cases} 1 - \sum_{k=1}^a V_{jk}^2, & Si \ i = j \\ \sum_{k=1}^a V_{jk}V_{ik}, & Si \ i \neq j \end{cases}$$

donde μ_j es la media de cada variable obtenida en la etapa de entrenamiento. Cada observación se estandariza con su media y su varianza para evitar sesgos por la magnitud de la variable. Nótese que la ecuación propuesta es simplemente una modificación a la ecuación reescrita del estadístico Q . Si $cont_{i,j} < 0$ o $r_i^2 < 9\sigma_i^2$, entonces forzosamente $cont_{i,j} = 0$. Finalmente se calcula la contribución global de la variable al estadístico como:

$$CONT_j = \sum_{i=1}^m cont_{i,j}$$

En la figura 3.18 se muestra la respuesta del estadístico Q ante la presencia de la falla descrita en la figura 3.17, y en la figura 3.19 se muestra la contribución de cada variable a dicho comportamiento.




Figura 3.18. Comportamiento del estadístico Q ante la presencia de stiction




Figura 3.19. Gráfico de las contribuciones de cada variable al comportamiento atípico del estadístico

Para este ejemplo las variables que más contribuyeron fueron la variable 22, la 9 y 11, las cuales son $\int EV_P^M dt$, $c(t)$ y $e(t)$ respectivamente, siendo la primera la que notoriamente más contribuyó a la falla, cumpliendo con las expectativas de la sección anterior.








4. METODO DE DIAGNOSTICO DE OSCILACIONES A TRAVES DE LA TENDENCIA DEL PROCESO

En el capítulo anterior se presentó una forma de detectar e identificar la presencia de stiction en la válvula de control mediante una estrategia híbrida de detección basada en modelos y en datos. En este capítulo se presenta una alternativa para el diagnóstico de las oscilaciones utilizando la tendencia de la variable controlada del lazo de control para discernir si la oscilación se debe al controlador o a la válvula de control. La tendencia de un lazo de control agresivo y la de uno con fricción estática son claramente diferenciables [79]; un controlador agresivo responde aproximadamente como una función sinusoidal, mientras que para un proceso autorregulado con una válvula defectuosa la respuesta tiende a ser sucesiones de exponenciales crecientes y decrecientes.

Este capítulo se divide de la siguiente manera: en primer lugar se presenta el método utilizado para la extracción de las tendencias, es decir, describir de manera cualitativa el comportamiento del lazo de control. En segundo lugar se presenta un método propuesto para diagnosticar la oscilación para procesos lineales y/o de estados conocidos, y finalmente se presenta un método para diagnosticar las oscilaciones si no se tiene suficiente información del proceso o este es altamente no lineal.

4.1. Identificación de tendencias de proceso

La idea de este capítulo es comparar la tendencia de la respuesta la variable controlada con una referencia, y de esta forma determinar la fuente de las oscilaciones. Para alcanzar este objetivo, lo primero que debe hacerse es extraer la tendencia de los datos del sensor. En [89] se propone una metodología formal para transformar la señal medida del sensor en una secuencia (combinación) de 7 elementos fundamentales llamados primitivas, con lo cuales se puede describir cualquier función continua o seccionalmente continua. En la tabla 4.1 se presentan las 7 primitivas con su descripción y características.

Primitiva	$\frac{d}{dt}$	$\frac{d^2}{dt^2}$	Tendencia
A	0	0	
B	+	+	
C	+	0	
D	+	-	
E	-	+	
F	-	0	
G	-	-	

A: Línea recta constante

B: Función cuadrática creciente; cóncava hacia arriba

C: Línea recta creciente

D: Función cuadrática creciente; cóncava hacia abajo

E: Función cuadrática decreciente; cóncava hacia arriba

F: Línea recta decreciente

G: Función cuadrática decreciente; cóncava hacia abajo

Tabla 4.1. Lenguaje fundamental del análisis de tendencias: Primitivas

La idea tras el método de extracción de tendencia es ajustar un polinomio mediante mínimos cuadrados al paquete de datos que se desea estudiar. Inicialmente se ajusta un polinomio de grado cero y se comprueba la significancia del modelo y la bondad de ajuste utilizando el ruido de la señal como referencia. Si el modelo no ajusta se repite el procedimiento hasta llegar a un polinomio de grado 2; si este último no ajusta, la ventana de datos se divide a la mitad y se repite el procedimiento. La ventana de datos se seguirá dividiendo entre dos hasta que un polinomio de grado dos o menos sea capaz de ajustar los datos.

Una vez se consigue un modelo que ajusta a los datos, se inicia nuevamente el procedimiento con los datos que fueron excluidos del modelo. Este procedimiento se repite hasta obtener una sucesión seccionalmente continua de polinomios que describen el comportamiento de la serie de datos.

Dado que las primitivas son funciones con primera y segunda derivadas constantes, la tarea de identificarlas a partir de una sucesión de polinomios es una tarea computacionalmente sencilla, la cual puede realizarse automáticamente junto con el cálculo de los polinomios. En la figura 4.1 se muestra la secuencia de primitivas de la señal de un sensor.




Figura 4.1. Tendencia y primitivas de un lazo de control oscilatorio

4.2. Diagnóstico de oscilaciones para procesos con estados conocidos

La idea en la que se fundamenta este método es el concepto de “Firma de proceso” propuesto por Venkatasubramanian *et al.* en [90], el cual afirma que una falla ocurrida en un proceso tiene una tendencia característica, o firma, independiente de la severidad de la falla. Para procesos simples esta asunción ajusta bien a la realidad.

Aunque dos tendencias tengan un comportamiento visiblemente similar, los mismos comportamientos fundamentales podrían producir una secuencia de tendencias ligeramente diferentes en orden y duración, debido a distintos factores como la variabilidad de los sensores, característica del ruido y/o fenómenos no estudiados. Por este motivo, intentar realizar una comparación estricta entre dos tendencias producirá una alta tasa de rechazo al momento de determinar la similitud o pertenecía de una tendencia a una firma de proceso.

En la figura 4.2 se muestran dos tendencias visiblemente similares, pero con distintos niveles de ruido en el sensor. Una comparación estricta entre estas dos tendencias rechazaría la hipótesis de que ambas tendencias son la misma. La propuesta de esta sección es utilizar lógica difusa para relacionar las primitivas con tendencias similares y determinar cierto grado de pertenencia entre ellas, de esta forma se puede tomar la tendencia del sensor de la variable controlada y compararla con las firmas del lazo oscilando debido al controlador y debido a la válvula de control.


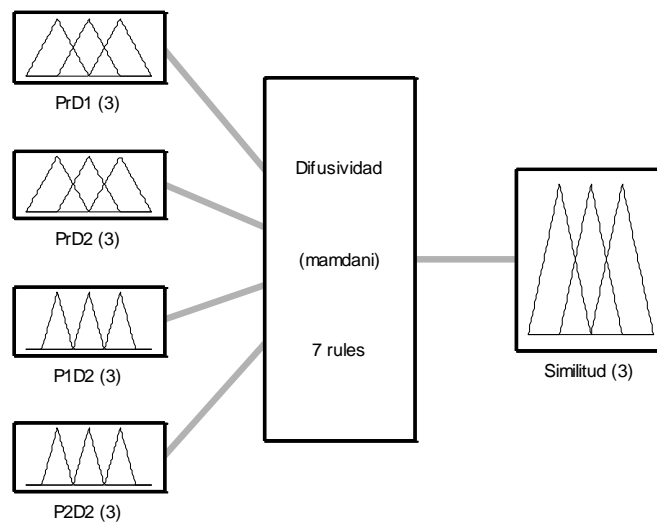


Figura 4.2. Comparación de la secuencia de primitivas de dos curvas similares con distintos niveles de ruido

Para relacionar las primitivas se utilizó un sistema de inferencia difuso (FIS) de Mamdani con 7 reglas base. En la figura 4.3 se presenta un resumen de la arquitectura del FIS. Se tienen un total de cuatro entradas; el producto entre las primeras derivadas de las primitivas que se van a comparar ($P_r D_1$), el producto entre las segundas derivadas de las primitivas a comparar ($P_r D_2$), y la segunda derivada de cada primitiva $P_1 D_2$ y $P_2 D_2$ respectivamente. La salida del FIS es el coeficiente de similitud entre las primitivas.



System Difusividad: 4 inputs, 1 outputs, 7 rules

Figura 4.3. Arquitectura del sistema cálculo de similitud difuso

Cada una de las variables de entrada puede tomar valor el valor de “Negative”, “Zero” y “Positive”, y la salida puede tomar los valores de “Low”, “Mid” y “High”. De la figura 4.4 a la figura 4.8 se muestran las funciones de pertenencia para cada variable.




Figura 4.4. Valores lingüísticos y función de pertenencia para P_rD_1




Figura 4.5. Valores lingüísticos y función de pertenencia para P_rD_2




Figura 4.6. Valores lingüísticos y función de pertenencia para P_1D_2




Figura 4.7. Valores lingüísticos y función de pertenencia para P_2D_2




Figura 4.8. Valores lingüísticos y función de pertenencia para el indicador similitud

En la tabla 4.2 se presentan las reglas utilizadas en el sistema de inferencia difusa.

SI				ENTONCES
$P_r D_1$	$P_r D_2$	$P_1 D_2$	$P_2 D_2$	S_i
+	+			High
-				Low
+	0			Mid
+	-			Mid
+	0			High
		0	0	High
0				Low

Tabla 4.2. Reglas para el apareamiento difuso de las primitivas

Las reglas del FIS fueron realizadas de tal forma que primitivas que exhiban el mismo tipo de comportamiento (ascendente o descendente) tengan un alto emparejamiento, mientras que aquellas que describan comportamientos diferentes tengan baja relación. Por otro lado se les atribuyó más semejanza a aquellas primitivas que no tuvieran cambio de signo en la segunda derivada, es decir se le da más valor si la segunda derivada de una primitiva es cero y la otra positiva o negativa, que si la segunda derivada de una es positiva y la otra negativa.

Como se tienen 7 primitivas existen un total de 49 apareamientos posibles entre ellas, utilizando el FIS presentado se tabularon los coeficientes de similitud para cada combinación posible. Los resultados se muestran en la tabla 4.3.

	A	B	C	D	E	F	G
A	1	0	0.25	0	0	0.25	0
B	0	1	0.75	0.5	0	0	0
C	0.25	0.75	1	0.75	0	0	0
D	0	0.5	0.75	1	0	0	0
E	0	0	0	0	1	0.75	0.5
F	0.25	0	0	0	0.75	1	0.75
G	0	0	0	0	0.5	0.75	1

Tabla 4.3. Matriz de similitud de primitivas

Ambas representaciones, lógica difusa o matricial, entregan el mismo coeficiente; se deja a decisión del lector cual le es más factible implementar en sus sistemas de monitoreo.

Una vez se tiene un coeficiente que relacione a cada primitiva individualmente, el siguiente paso es comparar una secuencia de primitivas, que es lo que usualmente se va a encontrar en la realidad. Para comparar una secuencia de primitivas se define un tiempo límite T_f dentro del cual se realiza la comparación; este tiempo límite cumple con ser el máximo tiempo común para dos cadenas de primitivas $P_r = \{P_{r1}, P_{r2}, \dots, P_{rm}\}$ y $P_r^* = \{P_{r1}^*, P_{r2}^*, \dots, P_{rn}^*\}$ con $m \neq n$, esto quiere decir ambas cadena de primitivas debe ser evaluada en el mismo intervalo de tiempo, pero es aceptable que la cantidad de primitivas difiera en cada cadena, esto se aprecia en la figura 4.2.

Para calcular el coeficiente global de similitud φ entre dos primitivas se realiza el siguiente procedimiento:

- ❖ Se realiza la unión de los dos conjuntos de primitivas para obtener K secciones intendentes. Por ejemplo, si se desea comparar la cadena de primitivas BDG con los siguientes tiempos de duración por primitiva $t_1 = \{[0 - 1][1 - 3][3 - 5]\}$, con la cadena de primitiva DE con los siguientes tiempos de duración $t_2 = \{[0 - 2][2 - 5]\}$, la combinación de los conjuntos quedaría $t_u = \{[0 - 1][1 - 2][2 - 3][3 - 5]\}$, en otras palabras $t_u = t_1 \cup t_2$. En este caso $K = 4$ y $T_f = 5$.

- ❖ En segundo lugar se calcula el coeficiente de similitud λ_i entre cada primitiva dentro del i^{th} intervalo ($i \leq K$). Continuando con el ejemplo anterior, en el primer intervalo $[0 - 1]$ están las primitivas B y D de la primera y segunda cadena respectivamente, por los cual $\lambda_1 = 0.5$ según la tabla 4.3, en el segundo intervalo $[1 - 2]$ están las primitivas D y D , por los cual $\lambda_2 = 1$, en el tercer intervalo $[2 - 3]$ están las primitivas D y E , por los cual $\lambda_3 = 0$, finalmente en el cuarto intervalo $[3 - 5]$ están las primitivas G y E , por los cual $\lambda_4 = 0.5$.
- ❖ Finalmente se calcula el coeficiente global φ como la media ponderada de los coeficientes de similitud individuales. El factor de ponderación de cada λ_i es el tiempo de cada intervalo dividido entre el tiempo total de comparación:

$$\varphi = \sum_{i=1}^K \lambda_i \frac{\Delta t_i}{T_f}$$

de esta forma, se le está dando más peso a los intervalos de comparación más largos. Para el caso del ejemplo mostrado:

$$\varphi = 0.5 * \frac{(1 - 0)}{5} + 1 * \frac{(2 - 1)}{5} + 0 * \frac{(3 - 2)}{5} + 0.5 * \frac{(5 - 3)}{5} = 0.5$$

En resumen, la estrategia propuesta consiste en utilizar el método de extracción de tendencias para determinar una cadena de primitivas correspondiente al comportamiento del controlador durante una oscilación de la cual se conozca su fuente y utilizarla como referencia para futuras oscilaciones. En este punto se determina el valor de T_f , este debe ser mínimo lo suficientemente grande para que el sistema alcance nuevamente el estado estable. Una vez establecida la referencia, se calcula constantemente la tendencia del proceso utilizando una ventana móvil; en estado normal de operación la tendencia identificada debería ser "A" (estado estable), el método de diagnóstico se inicia al identificar una tendencia diferente a esta. Una vez se detecta una tendencia diferente a "A", se fija el extremo inicial de la ventana de datos y se toman datos hasta alcanzar T_f . Finalmente se calcula el coeficiente de similitud global φ , entre los datos tomados y la cadena de primitivas de referencia. Se decide la fuente de la falla utilizando φ como criterio de decisión; si $\varphi_{controlador}$ es mayor que $\varphi_{válvula}$ la oscilación es causada a un controlador mal sintonizado, en caso contrario la oscilación se le atribuye a la válvula.

Dado que este es un enfoque basado en datos, cada nueva condición de operación puede incluirse en la base de datos, de esta forma se puede hacer robusto el método con el paso del tiempo. Si se tienen más de una tendencia de referencia se puede calcular φ para cada una de ellas y determinar el φ_{max} dentro de cada grupo (controlador o válvula) y comparar estos valores. En la figura 4.9 se presenta una muestra de lo mencionado.




Figura 4.9. Identificación de la tendencia con mayor índice de similitud global dentro de un mismo grupo de referencia.

4.3. Diagnóstico de oscilaciones para procesos de estados no conocidos

En la sección anterior se presentó un método de diagnóstico de oscilaciones basado en datos históricos del proceso, en el cual se comparaba la tendencia de la variable controlada con una firma representativa del proceso en condición oscilatoria. Un inconveniente del método anterior es que un controlador oscilatorio puede producir distintos tipos de oscilaciones en términos de cantidad de picos entre estados estables y desfases entre las ondas; esto se aprecia en la figura 4.10. Al ser un enfoque basado en datos, el método anterior tiene capacidad de aprendizaje y cada nuevo tipo de onda puede incluirse en una base de datos; este concepto enfrenta la problemática planteada bastante bien para procesos con pocas condiciones de operación, sin embargo, a medida que se incrementa la complejidad y la cantidad de estados del proceso este método se hace computacionalmente más complejo.




Figura 4.10. Comparación de dos tendencias de un lazo de control oscilatorio debido a una mala sintonía.

En esta sección se presenta un método de diagnóstico basado en modelos que no requiere información a priori del proceso para identificar la fuente de la oscilación. De manera análoga al método anterior, la tendencia del proceso se monitorea y el método de diagnóstico inicia al detectarse una tendencia distinta de A . utilizando el método mencionado en la sección 4.1 se extraen las tendencias entre dos estados estables consecutivos utilizando la ventana móvil que se mencionó en la sección anterior y se enlistan las primitivas.

Teniendo la secuencia de las primitivas, es posible detectar la presencia de una oscilación en el lazo de control. Si en la secuencia de primitivas ocurre un cambio de las primitivas B , C o D , que son primitivas ascendentes, a las primitivas E , F o G , que son primitivas descendentes, o viceversa, al menos dos veces consecutivas (de lo contrario no sería una oscilación sino overshoot), se dice que el lazo de control está oscilando.

Una vez se ha detectado que el lazo está oscilando se inicia el método de diagnóstico. Como ya se mencionó, en [79] se afirma que las tendencias de oscilaciones provenientes de una mala sintonía y las provenientes de una válvula defectuosa son diferentes; utilizando esta afirmación como base, se introduce el concepto de “reconstrucción de oscilaciones”, en donde básicamente, a partir de la información de la oscilación identificada, se genera analíticamente la tendencia de cómo debería comportarse una oscilación con la misma dinámica que la identificada si fuera causada por el controlador o por la válvula.

Para reconstruir la oscilación de un controlador agresivo, se utiliza la información presentada por Sanjuan *et al* en [91], donde se afirma que si una respuesta en lazo cerrado es oscilatoria, como la que se muestra en la figura 4.11, esta puede ser descrita como un sistema dinámico de segundo orden. Los parámetros analíticos a identificar para describir al sistema de segundo orden son la frecuencia natural amortiguada w_d y el coeficiente de amortiguamiento ξ . Para calcular estos parámetros se utilizará el periodo de la oscilación identificada, calculado como el tiempo entre dos cambios de signos análogos consecutivos en la primera derivada de la función; como se tiene la cadena de primitivas previamente, esta tarea es sencilla computacionalmente. Básicamente, se desea determinar cómo se comportaría una oscilación causada por un controlador agresivo si tuviera el mismo periodo que la oscilación identificada.




Figura 4.11. Respuesta subamortiguada de un sistema de segundo orden (Tomada de [91])

Para calcular la frecuencia natural amortiguada y el coeficiente de amortiguamiento a partir del periodo de la oscilación, se parte de la ecuación diferencial que describe a un sistema de segundo orden [91]:

$$\frac{d^2C(t)}{dt^2} + 2\xi w_N \frac{dC(t)}{dt} + w_N^2 C(t) = w_N^2 C^{SET}(t)$$

en donde, $C(t)$ es la señal del sensor en variable de desviación, $C^{SET}(t)$ es la señal del setpoint en variable de desviación y w_N es la frecuencia natural del sistema. Dado que la ecuación anterior es lineal, se puede reescribir en el dominio de la frecuencia utilizando la transformada de Laplace:

$$s^2 C(s) + 2\xi w_N C(s) + w_N^2 C(s) = w_N^2 C^{SET}(s)$$

$$G_{CLTF}(s) = \frac{C(s)}{C^{SET}(s)} = \frac{w_N^2}{s^2 + 2\xi w_N s + w_N^2}$$

Si se realiza un paso escalón Δ en el setpoint, se tiene que:

$$C(s) = \frac{\Delta w_N^2}{s(s^2 + 2\xi w_N s + w_N^2)} = \Delta \left[\frac{1}{s} - \frac{s + 2\xi w_N}{s^2 + 2\xi w_N s + w_N^2} \right]$$

$$C(s) = \Delta \left[\frac{1}{s} - \frac{s + \sigma}{(s + \sigma)^2 + w_N^2} - \frac{\sigma}{(s + \sigma)^2 + w_N^2} \right]$$

en donde, $\sigma = \xi w_N$ y $w_D = w_N \sqrt{1 - \xi^2}$. Utilizando la transformada inversa de Laplace, se obtiene la solución en el dominio del tiempo:

$$C(t) = \Delta \left[1 - e^{-\sigma t} \cos(w_D t) - \frac{\sigma}{w_D} e^{-\sigma t} \sin(w_D t) \right]$$

$$C(t) = \Delta \left[1 - e^{-\xi w_N t} \left[\cos(w_D t) + \frac{\xi}{\sqrt{1 - \xi^2}} \sin(w_D t) \right] \right]$$

Recordando que $A \cos(at) + B \sin(at) = D \sin(at + \theta)$, donde $D = \sqrt{A^2 + B^2}$ y $\theta = \tan^{-1} \left(\frac{A}{B} \right)$, la ecuación anterior se puede reescribir como:

$$C(t) = \Delta \left[1 - \frac{1}{\sqrt{1 - \xi^2}} e^{-\xi w_N t} \sin(w_D t + \theta) \right] \quad \theta = \tan^{-1} \left(\frac{\sqrt{1 - \xi^2}}{\xi} \right)$$

Definiendo $C_{SP}(t)$ como la desviación de la variable controlada del setpoint, se tiene que:

$$C_{SP}(t) = C^{SET}(t) - C(t) = \Delta - C(t)$$

$$C_{SP}(t) = \frac{\Delta}{\sqrt{1 - \xi^2}} e^{-\xi w_N t} \sin(w_D t + \theta)$$

Evaluando esta expresión en el tiempo en el que ocurre el primer pico t_1 , y un periodo después $t_1 + T_D$ se tiene que:

$$C_{SP}(t_1) = \frac{\Delta}{\sqrt{1 - \xi^2}} e^{-\xi w_N t_1} \sin(w_D t_1 + \theta)$$

$$C_{SP}(t_2) = \frac{\Delta}{\sqrt{1-\xi^2}} e^{-\xi w_N t_1} e^{-\xi w_N T_D} \sin(w_D t_1 + \theta)$$

Si se calcula la razón r_T entre estos dos valores se tiene que:

$$r_T = \frac{C_{SP}(t_1)}{C_{SP}(t_2)} = \frac{\frac{\Delta}{\sqrt{1-\xi^2}} e^{-\xi w_N t_1} \sin(w_D t_1 + \theta)}{\frac{\Delta}{\sqrt{1-\xi^2}} e^{-\xi w_N t_1} e^{-\xi w_N T_D} \sin(w_D t_1 + \theta)}$$

$$r_T = e^{\xi w_N T_D}$$

$$\ln(r_T) = \xi w_N T_D = \xi w_N \frac{2\pi}{w_D} = \xi w_N \frac{2\pi}{w_N \sqrt{1-\xi^2}} = \frac{2\pi\xi}{\sqrt{1-\xi^2}}$$

Por lo tanto,

$$\xi = \frac{\ln(r_T)}{\sqrt{4\pi^2 + \ln^2(r_T)}}$$

y por definición:

$$w_N = \frac{w_D}{\sqrt{1-\xi^2}} = \frac{2\pi}{T_D \sqrt{1-\xi^2}} = \frac{2\pi}{T_D \sqrt{1 - \left(\frac{\ln(r_T)}{\sqrt{4\pi^2 + \ln^2(r_T)}} \right)^2}}$$

Utilizando estos parámetros es posible generar el comportamiento que tendría un lazo de control mal sintonizado si tuviera el periodo de oscilación de los datos del sensor. En la figura 4.12a se muestra como ajusta la reconstrucción cuando la oscilación proviene de un controlador agresivo; se observa que el modelo ajusta adecuadamente a los datos del sensor, mientras que ajusta pobremente cuando las oscilaciones son producto de una válvula defectuosa, como se muestra en la figura 4.12b. Nótese que T_D se calcula utilizando únicamente los dos primeros picos de la oscilación.

Esta falta de ajuste al modelo es la base del método; una vez se calcula la tendencia analítica, se le extraen las primitivas (bien sea por el método de extracción propuesto o derivando analíticamente la ecuación), y estas se comparan con la primitivas de la señal del sensor utilizando el método difuso presentado en la sección anterior, de esta forma se obtiene un primer coeficiente de similitud.




Figura 4.12. Comparación del ajuste de la reconstrucción para (a) controlador agresivo (b) válvula con fricción estática

La obtención de la tendencia analítica de un lazo de control con una válvula que sufre de fricción estática, a diferencia de la reconstrucción anterior, se realiza de manera más cualitativa debido a la naturaleza de la dinámica que se podría observar.

Como ya se ha mencionado, en la literatura se afirma que una oscilación causada por fricción estática se describe cualitativamente como ondas triangulares y cuantitativamente como una secuencia de funciones exponenciales. Este comportamiento es principalmente el proceso respondiendo en lazo abierto ante el cambio súbito en la válvula (paso escalón) antes que el efecto de la retroalimentación afecte la respuesta. Si bien es cierto que los procesos industriales en lazo abierto son procesos de orden superior, en la práctica suelen aproximarse como sistemas de primer orden:

$$\tau \frac{dC(t)}{dt} + C(t) = K_p M(t)$$

en donde K_p y τ son la ganancia y la constante de tiempo del proceso respectivamente. Utilizando la transformada de Laplace se obtiene:

$$\begin{aligned} \tau s C(s) + C(s) &= K_p M(s) \\ G_p(s) &= \frac{C(s)}{M(s)} = \frac{K_p}{\tau s + 1} \end{aligned}$$

Si se realiza un paso escalón Δm en la señal de la válvula, se tiene que:

$$C(s) = \frac{K_p \Delta m}{s(\tau s + 1)}$$

$$C(s) = \frac{K_p \Delta m}{s} - \frac{K_p \Delta m \tau}{\tau s + 1}$$

Sacando la transformada inversa se obtiene la respuesta en el dominio del tiempo:

$$C(t) = K_p \Delta m [1 - e^{-t/\tau}]$$

Si a la respuesta del sistema se le calculan su primera y segunda derivada se obtiene:

$$\frac{dC(t)}{dt} = K_p \Delta m e^{-t/\tau} \qquad \frac{d^2C(t)}{dt^2} = -\frac{t}{\tau} K_p \Delta m e^{-t/\tau}$$

Para cualquier instante de tiempo, el valor de la primera derivada tendrá el signo de $K_p \Delta m$, y la segunda derivada tendrá el signo de $-K_p \Delta m$. Las primitivas que cumplen con esta condición (primera y segunda derivada de signos opuestos) son D y E , la primera cuando el lazo tiene tendencia ascendente y la segunda en el caso contrario. Lo que se propone es identificar zonas de acenso y descenso en la oscilación de los datos del sensor y reconstruir la oscilación utilizando sucesiones de estas primitivas. Comparando esta secuencia con las primitivas del sensor se obtiene un segundo coeficiente de similitud, y de manera análoga al método anterior, aquel coeficiente más cercano a la unidad representará al origen de la oscilación.

5. VALIDACION Y ANALISIS EN UN CASO DE ESTUDIO

Para validar el desempeño de las estrategias desarrolladas se realiza su implementación en un proceso tipo. El reactor endotérmico de flujo continuo presentado en [91], mostrado en la figura 5.1, se simula para este propósito. Este proceso es adecuado para la validación debido a su naturaleza no lineal, y a la cantidad de variables y parámetros que se pueden manipular, además de que no es un proceso ajeno a al ambiente industrial.

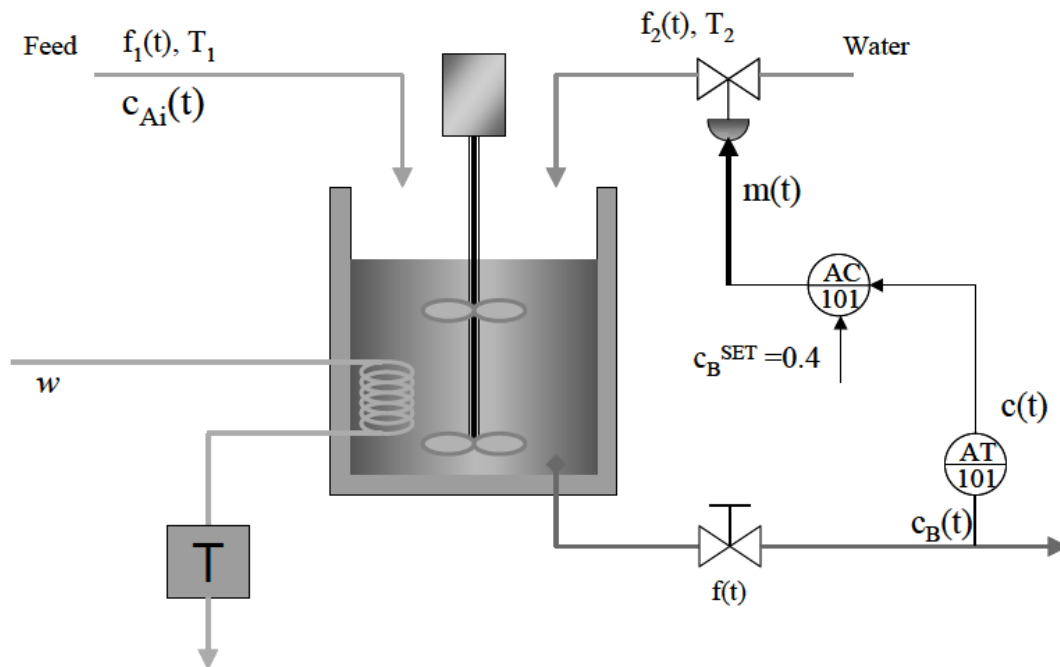




Figura 5.1. Reactor endotérmico de flujo continuo

Al reactor endotérmico ingresa el reactivo A en donde se descompone en los productos B y C. Este último a su vez se descompone en B y E de manera no reversible. Las siguientes ecuaciones estequiométricas rigen la dinámica de la reacción presente en el reactor:



Para que estas reacciones ocurran es necesario que al reactivo A se le añada agua como reactivo en exceso y calor, dado que dicha reacción es endotérmica con un calor de reacción dado. Por este motivo la segunda corriente que ingresa al reactor es agua pura y se utiliza el calor cedido por la condensación de un vapor para calentar la mezcla.

Para el desarrollo del modelo dinámico del reactor se realizaron las siguientes suposiciones:

- ❖ El reactor está bien mezclado y por lo tanto posee propiedades uniformes.
- ❖ No hay transferencia de calor entre el reactor y los alrededores.
- ❖ No hay transferencia de calor en la tubería.
- ❖ El vapor entra al serpentín como vapor saturado y sale como líquido saturado.

De la cinética de la reacción se conoce que:

$$r_A(t) = K_0 C_A(t) C_B(t) e^{-\frac{E}{RT(t)}} \quad 1ec, 4inc \{ r_A(t), C_A(t), C_B(t), T(t) \}$$

$$r_C(t) = K_0' C_A(t) C_C(t) \quad 2ec, 6inc \{ C_C(t), r_C(t) \}$$

Aparte, se sabe que la densidad del producto depende de la concentración B en el mismo de la siguiente manera:

$$\rho(t) = \rho_0 + dC_B(t) \quad 3ec, 7inc \{ \rho(t) \}$$

Sabiendo lo anterior se realizan los balances de masa correspondientes:

Balance de masa global:

$$\rho_0 f_1(t) + \rho_w f_2(t) - \rho(t) f(t) = A \frac{d}{dt} (h(t) \rho(t)) \quad 4ec, 9inc \{ f(t), h(t) \}$$

En donde:

$$f(t) = C_{val} \sqrt{h(t)} \quad 5ec, 9inc$$

Balance de componente A:

$$C_{A1}(t) f_1(t) - C_A(t) f(t) - A r_A(t) h(t) = A \frac{d}{dt} (h(t) C_A(t)) \quad 6ec, 9inc$$

Balance de componte B:

$$-C_B(t)f(t) + \frac{1}{2}Ar_A(t)h(t) + \frac{1}{2}Ar_C(t)h(t) = A \frac{d}{dt}(h(t)C_B(t)) \quad 7ec, 9inc$$

Balance de componte C:

$$-C_C(t)f(t) + \frac{1}{2}Ar_A(t)h(t) - Ar_C(t)h(t) = A \frac{d}{dt}(h(t)C_B(t)) \quad 8ec, 9inc$$

Seguidamente se plantean las ecuaciones de conservación de la energía.

Balance de energía en el reactor:

$$\rho_0 C p_1 \bar{T}_1 f_1(t) + \rho_w C p_w \bar{T}_w f_2(t) - \rho(t) C_p f(t) T(t) + UA_{coil}(T_c(t) - T(t)) + \\ -\Delta H R_A Ar_A(t)h(t) = A \frac{d}{dt}(h(t)\rho(t)) \quad 9ec, 10inc \quad \{ T_c(t) \}$$

Balance de energía en el serpentín:

$$\lambda W(t) - UA_c(T_c(t) - T(t)) = C p_{coil} \rho_{coil} L_{coil} \frac{dT_c(t)}{dt} \quad 10ec, 10inc$$

Además de las ecuaciones presentadas, debido al diseño del reactor, los sensores de concentración y temperatura se encuentran ubicados aguas abajo L_{pipe} pies del reactor, por lo cual se debe tener en cuenta el retraso por transporte que esto ocasiona en las variables de interés ($CB(t)$ y $T(t)$).

El tiempo muerto de este modelo se define como:

$$t_0(t) = \frac{L_{pipe} A_{pipe}}{f(t)} \quad 11ec, 11inc \quad \{ t_0(t) \}$$

Por lo cual:

$$CB_{downstream}^{(t)} = CB(t - t_0(t)) \quad 12ec, 12inc \quad \{ CB_{downstream}^{(t)} \}$$

$$T_{downstream}^{(t)} = T(t - t_0(t)) \quad 13ec, 13inc \quad \{ T_{downstream}^{(t)} \}$$

En la tabla 5.1 se presenta un listado de las propiedades termodinámicas y los estados estables del proceso.

<i>Variable</i>	<i>Valor</i>	<i>Unidad</i>
serpentín		
L_{coil}	240	ft
U	5.25	BTU/min ft ² °F
Cp_{coil}	0.14	BTU/lb °F
OD	4.5	in
ρ_l	11.2	lb/ft
Reacciones		
E	27820	BTU/lbmole
R	1.987	BTU/lbmole R
Ko	8.5×10^{10}	ft ³ /lbmoleB min
Ko'	41	ft ³ /lbmoleA min
ΔH_{R_A}	1000	BTU/lbmoleA
Válvula de descarga		
Cval	12.4	ft ³ /min/ft ^{0.5}
Alimentación		
ρ_0	68	lb/ft ³
d	2.4	lb/ft ³ /lbmoleB/ft ³
Cp1	0.85	BTU/lbm °F
Cv1	0.82	BTU/lbm °F

Vapor		
Λ	966	BTU/lb
Agua		
Cpw=Cvw	1	BTU/lbm °F
ρ_w	62.4	lb/ft ³
Producto		
Cp=Cv	0.9	BTU/lbm °F
Tubería		
L_{pipe}	180	Ft
ID	5.8	In
Reactor		
A	30	ft ²
Hmax	25	Ft
Valores en estado estable		
f1	18	ft ³ /min
f2	14	ft ³ /min
T1	140	°F
Tw	85	°F
CA1	0.95	lbmoleA/ft ³
W	40	lbm/min

Tabla 5.1. Parámetros de operación del reactor endotérmico

Para la identificación del proceso se necesario que este se encuentre instrumentado, puesto que las dinámicas y ganancias de los sensores y las válvulas utilizadas van embebidas en lo que el controlador ve como proceso, además de que físicamente es imposible realizar la identificación si no se tienen los instrumentos necesarios. Los sensores y las válvulas utilizadas, no son productos comerciales puesto que se seleccionaron con fines de la simulación. Los sensores se escogieron con un span suficientemente grande como para que no se saturaran ante cambios súbitos en perturbaciones o setpoint. Mientras que las válvulas se diseñaron para que en estado estable la señal de salida del controlador fuera de 50 %CO. El resumen de los instrumentos utilizados se muestra en la tabla 5.2.

Sensores				
Nombre	Span	T	Ubicación	
TT-101	0-250 °F	0.5 min	Aguas abajo del reactor	
AT-101	0-2 lbmole/ft^3	0.5 min	Aguas abajo del reactor	
Válvulas				
Tipo	Parámetros		τ	Ubicación
Proporcional	C_v^{max}	$59.42 \frac{ft^3}{\sqrt{psi}}$	0.5 min	Corriente de reactivo A
Proporcional	C_v^{max}	$42.36 \frac{ft^3}{\sqrt{psi}}$	0.25 min	Serpentín

Tabla 5.2. Listado de instrumentos ETR

De la tabla anterior se aprecia que las variables manipuladas escogidas son el flujo de carga (manipulada #1) y flujo de vapor (manipulada #2), mientras que las variables a controlar son la temperatura (controlada #1) y la concentración aguas abajo del reactor (controlada #2).

En la tabla 5.3 se presentan las variables utilizadas para el monitoreo del proceso, numeradas para futuras menciones.

Variable	Concepto	Variable	Concepto
$m(t)$ [1]	Señal del controlador	$V_p(t)$ [12]	Porcentaje de apertura de la válvula
$\frac{dm(t)}{dt}$ [2]	---	$\frac{dV_p(t)}{dt}$ [13]	---
$m_p(t)$ [3]	Parte proporcional de la señal del controlador	$\Delta P(t)$ [14]	Caída de presión
$\frac{dm_p(t)}{dt}$ [4]	---	$c_d(t)$ [15]	Señal del sensor de la perturbación
$m_i(t)$ [5]	Parte integral de la señal del controlador	$\frac{dc_d(t)}{dt}$ [16]	---
$\frac{dm_i(t)}{dt}$ [6]	---	$e_m(t)$ [17]	Error de modelaje
$m_d(t)$ [7]	Parte derivativa de la señal del controlador	$K_c(t)$ [18]	Ganancia del controlador
$\frac{dm_d(t)}{dt}$ [8]	---	$\tau_i(t)$ [19]	Tiempo integral
$c(t)$ [9]	Señal del sensor	$\tau_d(t)$ [20]	Tiempo derivativo
$\frac{dc(t)}{dt}$ [10]	---	$EV_p^M(t)$ [21]	Error de modelaje de la válvula
$e(t)$ [11]	Error	$\int EV_p^M(t)$ [22]	Integral del error de modelaje de la válvula

Tabla 5.3. Variables del lazo de control seleccionadas para el monitoreo del proceso

Cabe mencionar que se utilizaron las variables pertenecientes al lazo de control de temperatura, mientras se tomó como principal perturbación a la señal del controlador del lazo de concentración; es un escenario bastante común en la práctica que la principal perturbación de un lazo de control sea la dinámica otro lazo.

Para la etapa de entrenamiento se utilizan datos perturbados de tal forma que perturbaciones frecuentes no disparen al estadístico de prueba. En la figura 5.2 se muestra el comportamiento de las perturbaciones usuales del lazo de control.




Figura 5.2. Dinámica de las perturbaciones en el set de entrenamiento

Utilizando la respuesta de las variables ante estos patrones de comportamiento se realizó el entrenamiento del método de detección de fallas. Se obtuvieron cuatro componentes principales y las siguientes propiedades estadísticas del set de datos:

	T^2	Q
Media	3.99	0.652
Umbral	9.561	1.753
Desviación estándar	2.27	0.405

Tabla 5.4. Propiedades de los estadísticos de prueba

Utilizando estos valores se transforman los estadísticos de prueba en los estadísticos EWMA:

$$\kappa_i = 0.05T_i^2 + 0.95\kappa_{i-1} \quad \phi_i = 0.05Q_i + 0.95\phi_{i-1}$$

y se recalculan los umbrales de detección utilizando:

$$\begin{aligned} \kappa_u &= \kappa_0 + L_k \sigma_\kappa & \phi_u &= \phi_\phi + L_k \sigma_\phi \\ \kappa_u &= 3.99 + 4.736(2.27) \left(\frac{0.05}{2 - 0.05} \right) & \phi_u &= 0.652 + 3.748(0.405) \left(\frac{0.05}{2 - 0.05} \right) \\ \kappa_u &= 4.2657 & \phi_u &= 0.6909 \end{aligned}$$

Cabe mencionar que el set de entrenamiento se obtuvo utilizando una válvula de control que sufría de stiction leve ($S = 1$, $J = 0.1$), para simular el escenario en el que los datos fueron tomados en una planta que lleva algún tiempo trabajando.

Para verificar el comportamiento de los estadísticos en estado normal de operación, se realiza el monitoreo de los datos en estado estable del proceso. En la figura 5.3 se presenta el comportamiento del estadístico T^2 en condición normal de operación.




Figura 5.3. Estadístico de Hotelling para el estado estable del proceso

En la figura 5.4 se presenta el comportamiento del estadístico κ en condición normal de operación. Se observa que al transformar el estadístico se soluciona el problema de las falsas alarmas del método convencional.




Figura 5.4. Estadístico κ para el estado estable del proceso

Por otro lado, al haber una reducción en la variabilidad de las variables en estado estable con respecto a set de entrenamiento, en el estadístico Q no se presentan falsas alarmas, por lo cual no hay mejora con la transformación; esto se aprecia en la figura 5.5.




Figura 5.5. Comparación de los estadísticos Q y ϕ para el estado estable del proceso.

Para comprobar que la transformación de los estadísticos no afecta la capacidad de detección de fallas del metodo, se induce una falla al proceso para observar las respuestas de los estadísticos. La falla inducida al proceso fue una disminucion de $-7 \text{ ft}^3/\text{min}/\text{ft}^{0.5}$ en la capacidad de la válvula a la descarga, lo cual indica un taponamiento excecivo en la válvula. En la figura 5.6 se muestra la respuesta de los estadísticos.




Figura 5.6. Comportamiento de los estadísticos convencionales vs comportamiento de los estadísticos EWMA ante una falla súbita. (a) y (b) estadísticos convencionales, (c) y (d) estadísticos transformados

En la figura anterior se observa que los estadísticos responden adecuadamente ante la aparición de una falla en el proceso. Un punto a resaltar de la figura anterior es el comportamiento del estadístico ϕ ; en la figura 5.6(c) se observa que el estadístico Q supera ligeramente su umbral antes de regresar a condición “normal de operación”, esto se interpreta como una falsa alarma en este estadístico, sin embargo, en la figura 5.6(d) se muestra que ϕ supera su umbral considerablemente. Esto se debe a que los estadísticos EWMA son sensibles a cambios en la media del estadístico

original, por lo cual pueden detectar fallas de menos magnitud. Un comportamiento analogo ocurre entre T^2 y κ .

Para comprobar la capacidad de adelanto de los estadísticos EWMA ante la presencia fallas incipientes, se induce una rampa de pendiente $+0.001 \text{ lbmoleA/ft}^3$ en la concentración de entrada al reactor. En la figura 5.7 se muestra la comparación entre los desempeños de los estadísticos.




Figura 5.7. Comportamiento de los estadísticos convencionales vs comportamiento de los estadísticos EWMA ante una falla insipiente. (a) y (b) estadísticos convencionales, (c) y (d) estadísticos transformados

Ante la falla mencionada el estadístico T^2 la detecta a los 400 minutos, mientras que su análogo κ la detecta a los 200 minutos adelantándose 3 horas a la ocurrencia de la falla. Por otro lado, el estadístico Q detecta la ocurrencia de la falla a los 450 minutos, mientras que su análogo ϕ la detecta a los 350 minutos adelantándose una hora y media a la ocurrencia de la falla.

Para mostrar el desempeño de las ecuaciones de identificación en el espacio residual fuera de su propósito (detectar fricción estática), se le aplican a la falla inducida anteriormente. El gráfico de las contribuciones se muestra en la figura 5.8. Se cambió la escala de colores para mayor apreciación.




Figura 5.8. Gráfico de las contribuciones de cada variable al comportamiento atípico del estadístico, falla insipiente; crecimiento anormal en la concentración de entrada

Las principales variables responsables de la falla fueron la variable número 15 y la numero 17, las cuales corresponden a la principal perturbación del lazo de control, recordando que esta es la señal del segundo lazo, y el error de modelaje del proceso respectivamente. Estos resultados concuerdan con el tipo de falla que ocurre; se la concentración de entrada se incrementa, el lazo de concentración tratará de compensar la perturbación llevando su señal a niveles fuera de lo común.

Por otro lado, para evaluar la capacidad de identificación de stiction de las ecuaciones se induce una rampa de pendiente 0.1 en el parámetro S de la válvula, lo cual simula el envejeciendo paulatino de la válvula de control. En la figura 5.9 se presenta la respuesta de los estadísticos convencionales.




Figura 5.9. Estadísticos convencionales ante la presencia de fricción estática en la válvula (a) Estadístico T^2 (b) Estadístico Q

En la figura 5.10 se presenta el grafico de contribuciones para los estadísticos anteriores. Se observa que varias variables se salen de control, sin embargo la mayor contribución la siguen teniendo las variables 21 y 22, las cuales son el error de modelaje de la válvula y su integral respectivamente.




Figura 5.10. Gráfico de las contribuciones de cada variable al comportamiento atípico del estadístico, fricción estática en la válvula

Finalmente se evalúa el desempeño de la técnica de diagnóstico de oscilaciones propuesta. En la figura 5.11 se muestra el comportamiento de la variable controlada para distintos casos de sintonía y stiction.




Figura 5.11. Comportamiento de la variable controlada. (a) controlador correctamente sintonizado, sin stiction. (b) controlador correctamente sintonizado, con stiction. (c) controlador incorrectamente sintonizado, sin stiction. (d) controlador incorrectamente sintonizado, con stiction.

En la figura 5.11b se muestra el comportamiento de un controlador correctamente sintonizado ($K_c = 1 \frac{\%CO}{\%TO}$ $\tau_I = 3 \text{ min}$ $\tau_D = 2 \text{ min}$) el cual posee una banda de stiction de 2%CO. Al realizar la reconstrucción de la oscilación se obtuvieron los siguientes coeficientes de similitud:

$$\varphi_{\text{valvula}} = 0.9091$$

$$\varphi_{\text{controlador}} = 0.6647$$

En la figura 5.11c se muestra el comportamiento de un controlador mal sintonizado ($K_c = 3 \frac{\%CO}{\%TO}$ $\tau_I = 2 \text{ min}$ $\tau_D = 2 \text{ min}$) sin stiction. Al realizar la reconstrucción de la oscilación se obtuvieron los siguientes coeficientes de similitud:

$$\varphi_{valvula} = 0.8 \quad \varphi_{controlador} = 0.8366$$

En la figura 5.11d se muestra el comportamiento de un controlador mal sintonizado ($K_c = 3 \frac{\%CO}{\%TO}$ $\tau_I = 2 \text{ min}$ $\tau_D = 2 \text{ min}$) el cual posee una banda de stiction de 2%CO. Al realizar la reconstrucción de la oscilación se obtuvieron los siguientes coeficientes de similitud:

$$\varphi_{valvula} = 0.7813 \quad \varphi_{controlador} = 0.7484$$

Se omite el listado de las primitivas debido a su extensión. Se observa que el método es capaz de identificar la fuente de la oscilación, siendo más clara la diferencia a medida que el controlador sea menos agresivo.

6. CONCLUSIONES

Con la ejecución de esta investigación se desarrolló una estrategia de detección temprana, identificación y diagnóstico de fallas, que incorpora el desempeño del lazo de control como fuente de información. Se observó al realizar la pruebas de los métodos propuestos que se puede conseguir minimizar la tasa de falsas alarmas del método de detección de fallas convencional, anticipar la ocurrencia de fallas incipientes, incrementar la capacidad de detectar fallas de bajo impacto, y diagnosticar la fuente de un mal desempeño en el lazo de control.

Tras la finalización de este trabajo, se puede concluir lo siguiente:

- ❖ Ponderar exponencialmente los estadísticos convencionales, causa que estos sean insensibles a cambios súbitos, lo cual reduce la tasa de falsas alarmas, y sensible a cambios graduales, lo cual permite anticipar fallas incipientes y detectar fallas de baja magnitud.
- ❖ Rescribiendo la definición del estadístico Q se puede calcular la contribución de cada variable al estadístico; de esta forma se puede identificar que variables son significativas a la desviación del proceso de su condición normal de operación.
- ❖ El error de modelaje de la válvula es una variable significativa para la detección de stiction en una válvula de control.
- ❖ La tendencia del proceso puede ser aprovechada como fuente de información en el diagnóstico de un mal desempeño de los lazos de control; la tendencia cualitativa entre una oscilación causada por un controlador agresivo difiere de la causada por una válvula de control defectuosa.

Por otro lado, a lo largo del documento se presentaron dos métodos para identificar fricción estática; el primero basado en una combinación híbrida entre métodos de detección de fallas basada en datos y en modelos, y la segunda en base a la tendencia del proceso. Para futuras investigaciones se propone incorporar ambos métodos a un esquema de control adaptativo, de tal forma que se pueda compensar un mal desempeño del controlador sin correr el riesgo de cubrir una falla en la válvula en el proceso. En la figura 6.1 se muestra el esquema propuesto.

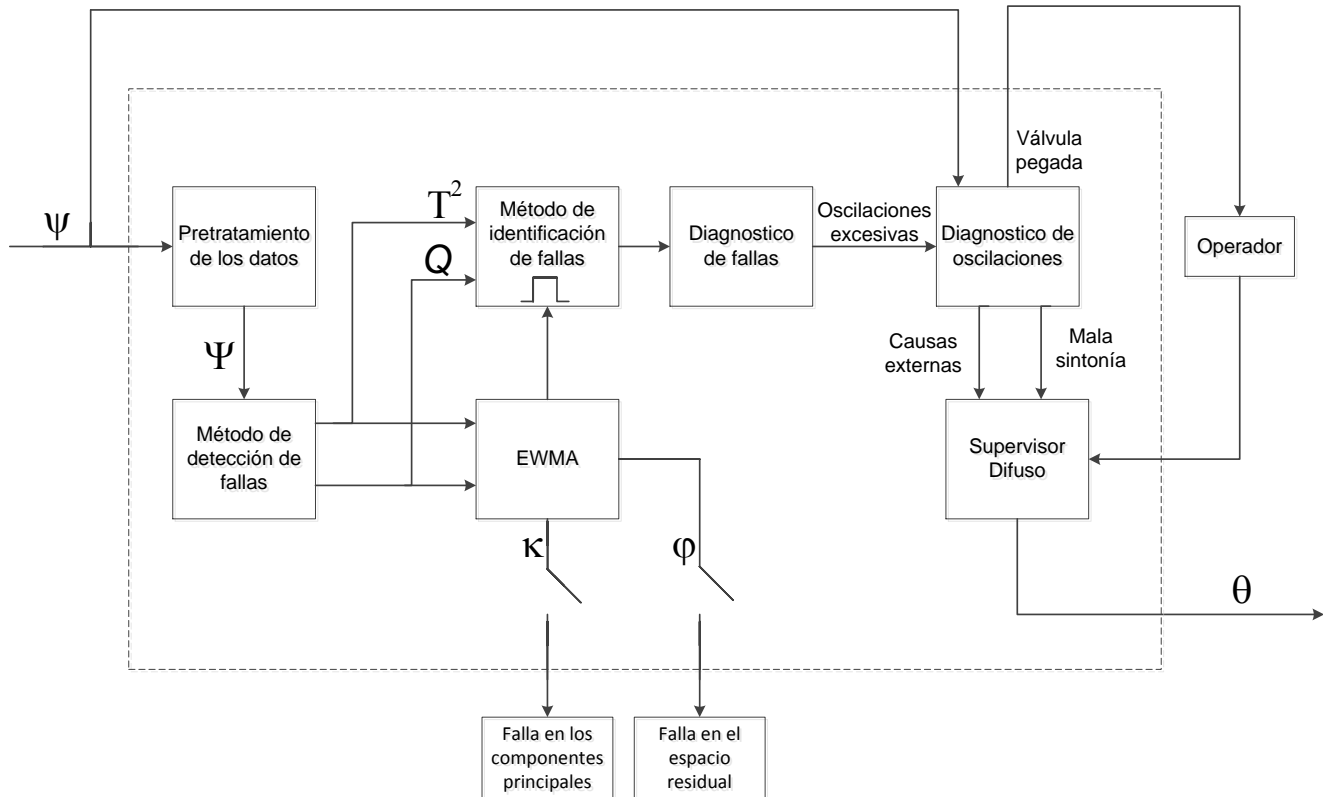


Figura 6.1. Incorporación de los métodos desarrollados con un esquema de control adaptativo

Los datos provenientes del lazo de control (ψ), reciben un pretratamiento con el objetivo de eliminar sesgo en los datos debido a las diferencias entre las magnitudes de cada variable. Seguido, los datos pretratados (Ψ) llegan a un bloque de detección de fallas multivariado, en el cual se calculan los estadísticos de prueba. Para la metodología propuesta se utiliza PCA como método calcular los estadísticos de prueba T^2 y Q . A los estadísticos se les aplica la transformación presentada, de tal forma que se afirma la existencia de una falla si el estadístico EWMA supera su umbral. Si se detecta una falla, se envía una alarma al operador e inicia el proceso de identificación de la falla. Una vez identificadas las principales variables causantes de la condición atípica, se llega a un bloque de diagnóstico, en el cual se evalúa si la alarma se disparó debido a oscilaciones excesivas en el lazo de control. En caso afirmativo, el siguiente paso es identificar la fuente de las oscilaciones. Si la causa es mala sintonía se pasa directamente al siguiente bloque, y si la oscilación se debe a la válvula de control se deja a decisión del operador si desea seguir al siguiente bloque o reparar la válvula manualmente. El último bloque es un supervisor difuso encargado de cambiar la sintonía del controlador dependiendo de las características del proceso. La salida de este bloque son los parámetros de sintonía del controlador.

REFERENCIAS

- [1] Isermann, R. (1984): "Process fault detection based on modeling and estimation methods--A survey." *Automatica*. 20, pp. 387-404.
- [2] Ender, D. B. (1993): "Process control performance: Not as good as you think." *Control Engineering*, 40:10, pp. 180-190.
- [3] Bialkowski, W. L. (1993): "Dreams versus reality: A view from both sides of the gap." *Pulp and Paper Canada*, 94:11.
- [4] Hagglund, T. (1995). A CONTROL-LOOP PERFORMANCE MONITOR. *Control Engineering Practice*, 1543-1551.
- [5] Shinskey, F. G. (1990): "How good are our controllers in absolute performance and robustness?" *Measurement and Control*, 23, May, pp. 114-121.
- [6] Smith, C., & Corripio, A. (2006). *Principles and Practice of Automatic Process Control*. United states of America: Wiley.
- [7] Forsman, K., & Stattin, A. (1999). A new criterion for detecting oscillations in control loops .In *European control conference*, Karlsruhe, Germany.
- [8] Miao, T, & Seborg, D.E. (1999). Automatic detection of excessively oscillatory feedback control loops. In *Proceedings of IEEE conference on control applications*, Hawaii, pp.359–364.
- [9] Thornhill, N.F.,Huang, B.,&Zhang,H.(2003).Detection of multiple oscillations in control loops. *Journal of Process Control*, 13, 91–100.
- [10] Srinivasan, R., Rengaswamy, R., & Miller, R. (2007). A modified empirical mode decomposition (EMD) process for oscillation characterization in control loops. *Control Engineering Practice*, 15(9), 1135–1148.
- [11] Thornhill, N. F., & Hagglund, T. (1997). Detection and diagnosis of oscillation in control loops. *Control Engineering Practice*, 5, 1343–1354.
- [12] Desborough, L. D., & Harris, T. J. (1992). Performance assessment measures for univariate feedback control. *Canadian Journal of Chemical Engineering*, 70, 1186–1197.

- [13] Tangirala, A. K., Shah, S. L., & Thornhill, N. F. (2005). PSCMAP: A new tool for plant-wide oscillation detection. *Journal of Process Control*, 15, 931–941.
- [14] Matsuo, T., & Sasaoka, H. (2005). Application of wavelet transform to process behavior monitoring. *Journal of Society of Instrument and Control Engineers*, 44, 139–142.
- [15] Russell, E., Chiang L & R. D. Braatz. (2005). *Data-Driven Techniques for Fault Detection and Diagnosis in Chemical Processes*. Great Britain: Springer-Verlag,
- [16] A.K. Samantaray, K. Medjaher, B. Ould Bouamama, M. Staroswiecki, G. Dauphin-Tanguy. (2005.). Diagnostic bond graphs for online fault detection and isolation. Department of Mechanical Engineering, Indian Institute of Technology, 721 302 Kharagpur, India.
- [17] R. Isermann and P. Ballé. Trends in the application of model based fault detection and diagnosis of technical processes. In *Proc. of the 13th IFAC World Congress*, volume N, pages 1-12, Piscataway, NJ, 1996. IEEE Press.
- [18] P.M. Frank. (1996). Analytical and Qualitative Model-based Fault Diagnosis – A Survey and Some New Results. *European Journal of Control* 2:6-28.
- [19] M. Staroswiecki, G. Comtet-Varga. (2001). Analytical redundancy relations for fault detection and isolation in algebraic dynamic systems. *Automatica* 37, pp. 687-699.
- [20] D.C. Montgomery, *Design and Analysis of Experiments*, 5th ed., JohnWiley and Sons, New York, USA, 2001.
- [21] V. Venkatasubramanian, R. Rengasamy, S.N. Kavuri, K. Yin. (2003). A review of process fault detection and diagnosis: Part III: Process history based methods. *Computer & Chemical Engineering*. 27, pp. 327-346.
- [22] M.A. Bin Shams, H.M. Budman, T.A. Duever. (2011) .Fault detection, identification and diagnosis using CUSUM based PCA. *Chemical Engineering Science* 66, pp4488-4498.
- [23] A. Alkaya, I. Eker. (2011) .Variance sensitive adaptive threshold-based PCA method for fault detection and diagnosis. *ISA Transactions* 50, pp 287-302.

- [24] P. Maravelakis, P. Castagliola. (2009). EWMA chart for monitoring the process standard deviation when parameters are estimated. *Computational Statistics and Data Analysis* 53, pp 2653-2664.
- [25] Crowder, S.V. (1987). A simple method for studying run length distributions of exponentially weighted moving average control charts, *Technometrics*, 29, 401-407.
- [26] Saccucci, M., & Lucas, J. (1990). Exponentially Weighted Moving Average Control Schemes: Properties and Enhancements . *TECHNOMETRICS*.
- [27] MacGregor, J. (1994). Statistical process control of multivariate processes. In *Proc. of the IFAC Conference on Advanced Control of Chemical Processes*, pages 427-435, New York.
- [28] Kresta, J., Macgregor, J., & Marlin, T. (1991). Multivariate statistical monitoring of process operating performance. *The Canadian Journal of Chemical Engineering*, 35-47.
- [29] Dunia, R., Qin, J., Edgar, T., & McAvoy, T. (1996). Identification of faulty sensors using principal component analysis. *AIChE Journal*, 2797-2812.
- [30] Q. Chen, U. Kruger, M. Meronk, A.Y.T. Leung. (2004). Synthesis of T^2 and Q statistics for process monitoring. *Control Engineering Practice* 12, pp 745-755.
- [31] Duda, R., & Hart, P. (1973). *Pattern Classification and Scene Analysis*. New York: Wiley.
- [32] J. Lee, C. Yoo and I. Lee. (2004). Statistical process monitoring with independent component analysis. *J. Process Control*, vol. 14, pp. 467-485, 8.
- [33] G. Stefatos, A.B. Hamza. (2010). Dynamic independent component analysis approach for fault detection and diagnosis. *Expert Systems with Applications* 37, pp 8606-8617.
- [34] Geladi, P, & Kowalski, B. R. (1997). Partial Least Squares regression: a tutorial. *Analytica Chimica Acta*, 185:1-17.
- [35] Chiang L., Russell E. & Braatz R. (2000). Fault diagnosis in chemical processes using Fisher discriminant analysis, discriminant partial least

squares, and principal component analysis. *Chemometrics and Intelligent Laboratory Systems* 50, pp 243–252.

[36] Piovoso, M. J. & Kosanovich, K. A. (1994). Applications of multivariate statistical method to process monitoring and controller design. *Int. J. of Control*, 59:743-765

[37] P. Burrell and D. Inman. (1997). An expert system for the analysis of faults in an electricity supply network: Problems and achievements. *Computers in industry*, 37(2):113-123.

[38] Portnoy, Iván D. Diseño de un método adaptativo de detección temprana de fallas para la reducción de falsas alarmas debidas al envejecimiento de procesos y a la incertidumbre estadística, m.s. tesis, universidad del norte, barranquilla, Colombia, 2014.

[39] V. Patel, A. Patel. Recent Advances In AI Based Intelligent Fault Technique For Rolling Element Bearing – A Review. *International Journal of Artificial Intelligence and Mechatronics*, Volume 2, Issue 4, (104-108) ISSN 2320-5121.

[40] S. Wold. Exponentially weighted moving principal component analysis and projection to latent structures, *Chemometrics and Intelligent Laboratory systems* 23 (1994) 149-161.

[41] S.J. Qin. Statistical process monitoring: Basics and beyond. *J Chemom* 2003; 17 (8-9): 480-502.

[42] Weihua Li. J. Qin. Consistent dynamic PCA based on errors-in-variables subspace identification. *Journal of Process Control* 11 (2001) 661-668.

[43] J.C. Jeng. Adaptive process monitoring using efficient recursive PCA and moving window PCA algorithms. *Journal of the Taiwan Institute of Chemical Engineers* 41 (2010) 475–481. 2010.

[44] X. Liu, U. Kruger, L. Xie, S. Wang. Moving window kernel PCA for adaptive monitoring of nonlinear process. *Chemom Intell Lab Syst* 2009; 96 (2): 132-43.

[45] S.J. Qin. Recursive PLS algorithms for adaptive data modelling. *Comput Chem Eng* 1998; 22 (4-4): 503-14.

- [46] S.R. Samantaray, P.K. Dash, S.K. Upadhyay. Adaptive Kalman filter and neural network based high impedance fault detection. *Electrical Power and Energy Systems* 31 (2009) 167-172.
- [47] Garcia, H & Vilim, R. Combining physical modeling, neural processing, and likelihood testing for online process monitoring. In *Proc. Of the IEEE international Conference on Systems, Man and Cybernetics*, volume 1, pages 806-810, Piscataway, NJ, 1998. IEEE Press.
- [48] Zhao, J., Chen, B. & Shen, J. A hybrid ANN-ES system for dynamic fault diagnostic of hydrocracking process. In *joint 6th International Symposium on Process Systems Engineering and 30th European Symposium on Computer Aided Process Engineering*, pages S929-S933, Oxford, U.K., 1997. Elsevier Science Ltd.
- [49] Zhang, Y., Li, X., Dai, G., Zhang, H., & Chen, H. Fault detection and identification of dynamic systems using multiple feedforward neural networks. In *Proc. of the 13th IFAC World Congress, Volume N*, pages 241-246. Piscataway, NJ, 1996. IEEE press.
- [50] Englemore, R., Morgan, T. *Blackboard systems*. Addison-Wesley, Menlo Park, CA, 1988.
- [51] Mylaraswamy, D., Venkatasubramanian, V. A hybrid framework for large scale process fault diagnosis. In *Joint 6th International Symposium on Process Systems Engineering and 30th European Symposium on Computer Aided Process Engineering*, pages S935-S940, Oxford, U.K., 1997. Elsevier Science Ltd.
- [52] Astrom, K. J. (1983). Theory and Applications of Adaptive Control - A Survey. *Automatica*, 471-486.
- [53] Truxal, J. G. (1964). Theory of self-adjusting control. *Proc. 2nd IFAC World Congress*.
- [54] Saridis, G. N., J. M. Mendel and Z. Z. Nikolic (1973). Report on definitions of self-organizing control processes and learning systems. *IEEE Control Systems Society Newsletter*.
- [55] Aseltine, J. A., A. R. Mancini and C. W. Sarture (1958). A survey of adaptive control systems. *IRE Trans, AC-6*, 102.
- [56] Stromer, P. R. (1959). Adaptive or self-optimizing control systems--a bibliography. *IRE Trans, AC-7*, 65.

- [57] Landau, I. D. (1974). A survey of model reference adaptive techniques: theory and applications. *Automatica*, 10, 353.
- [58] Wittenmark, B. (1975). Stochastic adaptive control methods a survey. *Int. J. Control*, 21, 705.
- [59] Tsypkin, Y. Z. (1975). *Foundations of the Theory of Learning Systems*. Academic Press, New York.
- [60] Asher, R. B., D. Adrisani and P. Dorato (1976). Bibliography on adaptive control systems. *IEEE Proc.*, 64, 1126
- [61] Astrom KJ, Wittenmark B (1995) *Adaptive Control*, 2nd edn. Addison Wesley, Boston, MA, USA
- [62] Jain, P., & Nigam, M. (2013). Design of a Model Reference Adaptive Controller Using Design of a Model Reference Adaptive Controller Using. *Advance in Electronic and Electric Engineering*, 477-484 .
- [63] Gauss, K. F., 1809. *Theoria motus corpusum coelestium*, (In Latin). English translation: *Theory of the Motion of the Heavenly Bodies*. New York: Dover, 1963.
- [64] Choudhury, M.A.A.S., N.F. Thornhill, and S.L. Shah (2004). A Data-Driven Model for Valve Stiction. *IFAC Symposium on Advanced Control of Chemical Processes (ADCHEM)*, Hong-Kong, Jan. 11–14.
- [65] Muller, F. (1994). Simulation of an Air Operated Sticky Flow Control Valve. *Proc. of the 1994 Summer Computer Simulation Conference*, 742–745.
- [66] Taha, O., G. A. Dumont and M. S. Davies (1996). Detection and diagnosis of oscillations in control loops. In: *Proceedings of 35th conference on Decision and Control*. Kobe, Japan.
- [67] A. Horch, A.J. Isaksson, A method for detection of stiction in control valves, in: *Proc. IFAC Workshop on On-line Fault Detection and Supervision in Chemical Process Industry*, Lyon, France, 1998, p. session 4B.
- [68] A. Stenman, F. Gustafsson, K. Forsman, A segmentation-based method for detection of stiction in control valves, *Intl. J. Adaptive Control Signal Process.* 17 (2003) 625–634

- [69] A. Horch, A simple method for detection of stiction in control valves, *Control Eng. Practice* 7 (1999) 1221–1231.
- [79] Singhal, A., & Salsbury, T. (2005). A simple method for detecting valve stiction in oscillating control loops. *Process control*, 371-382.
- [80] M. Ruel, Valve diagnosis identifies process problems, in: *Proc. ISA Western Regional Conf. and Exhibition*, Las Vegas, NV, 2002.
- [81] M.A.A.S. Choudhury, S.L. Shah, N.F. Thornhill, Diagnosis of poor control-loop performance using higher order statistics, *Automatica* 40 (2004) 1719–1728.
- [82] Choudhury, T. A friction compensator for pneumatic control valves, *Journal of Process Control* 12 (2002) 897–904.
- [83] Z.X. Ivan, S. Lakshminarayanan, A new unified approach to valve stiction quantification and compensation, *Industrial and Engineering Chemistry Research* 48 (2009) 3474–3483.
- [84] B. Halimi, Y. Suh Kune, Analysis of nonlinearities compensation for control valves, in: *Proceedings of International Congress on Advances in Nuclear Power Plants (ICAPP 2010)*, June 13–17, San Diego, CA, USA, 2010.
- [85] R. Srinivasan, R. Rangaswamy, Approaches for efficient stiction compensation in process control valves, *Computer and Chemical Engineering* 32 (2008) 218–229.
- [86] Mohammad, M., & Huang, B. (2012). Compensation of control valve stiction through controller tuning. *Journal of Process Control*, 1800-1819.
- [87] M. Ale Mohammad, B. Huang, Frequency analysis and experimental validation for stiction phenomenon in multi-loop processes, *Journal of Process Control* 21 (4) (2011) 437–447.
- [88] M. Torres. Diseño de un método híbrido de detección de fallas y reconocimiento de patrones para procesos industriales, (2012). Tesis de Maestría, Universidad del Norte
- [89] Janusz, M., and V. Venkatasubramanian, “Automatic Generation of Qualitative Description of Process Trends for Fault Detection and Diagnosis,” *Eng. Applic. Artif. Intell.*, 4(5), 329 (1991).

[90] Dash, S., Rengaswamy R., Venkatasubramanian, V. "Fuzzy-Logic based trend classification for fault diagnosis of chemical processes". Computer & Chemical Engineering 27 (2003), 347-362

[91] M. Sanjuan, A. Kandel, C.A. Smith, Design and implementation of a fuzzy supervisor for on-line compensation of nonlinearities: An instability avoidance module, Engineering Applications of Artificial Intelligence, Volume 19, Issue 3, April 2006, Pages 323-333